
**應用人工智慧結合紅色地圖判釋集水區內
地質災害潛勢**

**The application of Artificial Intelligence
and Red Relief Image Map in interpreting
geological disaster potentials in watersheds**

執行單位：國立成功大學全球觀測與資料分析中心

執行期間：108 年 02 月 20 日至 108 年 12 月 31 日

計畫主持人：劉正千 特聘教授

共同主持人：陳培殷 特聘教授

行政院農業委員會水土保持局 編印

中華民國 108 年 12 月

(本報告書內容及建議純屬執行單位意見，僅供本局施政參考)

應用人工智慧結合紅色地圖判釋集水區內地質災害潛勢

摘要

根據長期且詳盡的崩塌目錄，建立可靠的崩塌潛勢指標 (Landslide Susceptibility Index, LSI)，是預防和減輕崩塌危害最重要的資訊之一。本研究使用坡度、坡向、累積通量、岩性、數值高程等普遍可取得的崩塌潛勢因子，輔以具有空間視覺特徵之紅色地圖，訓練卷積類神經網路，建立卷積崩塌潛勢指標模式；再提出損失函式出現頻率權重加乘的方式，解決了因崩塌與非崩塌比例懸殊所導致訓練結果表現不佳的問題。另外，我們測試了 57 種因子組合之模式，結果發現由全部 6 種因子建立之卷積崩塌潛勢指標模式為最佳的模式，紅色地圖對建立的卷積崩塌潛勢指標模式有正向的影響；而且透過消融分析 (ablation study)，發現含有累積通量的模式表現較好，其他因子的重要性依序為岩性、坡向、坡度、數值高程與紅色地圖。本研究的成果可結合水文、氣象、以及地理資訊資料，將可作為一趨勢模型，用以預測崩塌災害發生之可能性，並據以評估所導致的危害與風險。

關鍵字：深度學習、人工智慧、崩塌潛感模式、卷積類神經網路

The application of Artificial Intelligence and Red Relief Image Map in interpreting geological disaster potentials in watersheds

Abstract

Establishing a reliable Landslide Susceptibility Index (LSI) map based on a long-term and detailed catalog of landslides is one of the most important tasks to prevent and mitigate the risk of landslides. In this study, the widely available and common preparatory factors such as slope, aspect, total flux, lithology, and digital elevation map are collected, and the red relief image maps with 3D visualization characteristics are supplemented to construct a convolutional LSI model. The frequency multiplication balancing method has been validated to be able to improve the model performance by weighting the loss function for the landslide unbalancing data. We trained various LSI models with 57 different combinations of 6 preparatory factors. The model with all 6 preparatory factors has the largest area under the receiver operating characteristics. Moreover, the ablation study has indicated that the models with total flux factor are good models, and the order of importance of factors affecting the LSI model is lithology, aspect, slope, digital elevation, and red map. With the technique of spatial analysis of geographical information, the convolutional LSI model of this study in combination with other hydrology and weather data can be incorporated into the process of prediction and risk assessment of landslide disasters.

Keywords: deep learning, AI, LSI model

目次

摘要.....	I
Abstract.....	II
目次.....	III
表次.....	V
圖次.....	VI
第一章 前言	1-1
第一節 地質災害	1-1
第二節 崩塌潛勢指標與模型	1-2
第三節 紅色地圖	1-4
第四節 計畫目標	1-6
第二章 研究進度與內容	2-1
第一節 研究內容	2-1
第二節 研究進度	2-3
第三章 研究區域與材料	3-1
第一節 研究區域	3-1
第二節 崩塌目錄	3-4
第三節 崩塌潛勢因子	3-6
第四節 深度學習方法	3-16
第四章 研究方法與步驟	4-1
第一節 準備資料	4-2
第二節 模式設計	4-5
第三節 模式訓練與驗證	4-6
第四節 崩塌潛勢指標預測表現	4-9
第五節 開發平台與深度學習模組	4-10

第五章 研究成果	5-1
第一節 潛勢因子的編碼	5-1
第二節 損失權重調整	5-5
第三節 模式深度	5-8
第四節 潛勢因子組合	5-11
第六章 結論及建議	6-1
參考文獻.....	參-1
附錄.....	附錄-1
附錄一、期初審查會議記錄暨回覆辦理情形	附錄-1
附錄二、期中報告書審查意見暨回覆辦理情形	附錄-6
附錄三、期末報告審查意見暨回覆辦理情形	附錄-9
附錄四、2019 臺灣地球科學聯合學術研討會摘要	附錄-15
附錄五、2019 地球觀測及社會衝擊國際研討會摘要	附錄-16
附錄六、2019 地球觀測及社會衝擊國際研討會海報發表	附錄-17

表次

表 2-1	完成工作進度表	2-3
表 3-1	水土保持技術規範之坡度分級	3-8
表 3-2	研究區域之岩性分類	3-12
表 5-1	深度類神經網路與 CloudNet 架構訓練參數量與時間 ...	5-10
表 5-2	最佳的卷積潛感模式預估 LSI 的表現.....	5-18
表 6-1	最佳的卷積潛感模式預估與過去研究比較	6-1

圖次

圖 1-1	於 BigGIS 上呈現之 H.O.S.T 地圖	1-6
圖 3-1	宜蘭太平山地區位置圖	3-1
圖 3-2	花蓮和中部落崩塌前累積雨量圖	3-3
圖 3-3	和中雨量站降雨組體圖	3-3
圖 3-4	101 年蘇拉颱風過後花蓮和中部落崩塌狀況	3-4
圖 3-5	受地震影響建議調整之土石流警戒基準值範圍圖	3-4
圖 3-6	坡度因子評分值	3-8
圖 3-7	坡度因子評分之分布圖	3-9
圖 3-8	坡向因子評分值	3-10
圖 3-9	坡向因子評分之分布圖	3-11
圖 3-10	岩性因子評分值	3-12
圖 3-11	岩性因子評分之分布圖	3-13
圖 3-12	累積通量因子評分值	3-15
圖 3-13	累積通量因子評分之分布圖	3-15
圖 3-14	宜蘭太平山研究區域紅色地圖	3-16
圖 3-15	類神經網路運算模型的範例	3-17
圖 3-16	Gradient descent 範例	3-20
圖 3-17	批次梯度下降法收斂曲線示意圖	3-21
圖 3-18	隨機梯度下降法收斂曲線示意圖	3-22
圖 3-19	訓練過程中權重參數變動幅度的過程	3-24
圖 3-20	在輸入層加入 batch normalized layer	3-25
圖 3-21	使用 Drop out 之範例	3-26
圖 3-22	GoogLeNet 架構與後段的 inception layer	3-29
圖 4-1	深度學習測試步驟	4-2

圖 4-2	模式訓練資料之崩塌像素直方圖	4-4
圖 4-3	CloudNet 架構圖	4-6
圖 4-4	接受者操作特徵 (ROC) 曲線	4-9
圖 5-1	資料編碼對 CloudNet 架構訓練後的模式表現	5-2
圖 5-2	複數平面上的單位圓	5-3
圖 5-3	不同的損失函式權重方法對模式的預測表現.....	5-6
圖 5-4	5 個潛勢因子加乘損失函數權重訓練的模式表現.....	5-7
圖 5-5	紅色地圖加乘損失函數權重訓練的模式表現.....	5-8
圖 5-6	深度類神經網路與 CloudNet 崩塌潛勢指標模式表現 ...	5-10
圖 5-7	深度類神經網路對 LSM 的學習成效	5-11
圖 5-8	57 種因子組合訓練模式後預測宜蘭太平山區域資料之 ROC 曲線下面積熱度圖	5-13
圖 5-9	57 種因子組合訓練模式後預測花蓮和中區域資料之 ROC 曲 線下面積熱度圖	5-15
圖 5-10	4 因子模式與 5 因子模式因子重要性比較圖	5-17

第一章 前言

第一節 地質災害

地質災害是指自然或人為引發之地震、海嘯、火山、斷層活動、山崩、地滑、土石流、地層下陷、海岸變遷或其他地質作用所造成之災害 (地質法 中華民國 99)。而台灣位於歐亞大陸板塊與菲律賓板塊交界上，屬環太平洋地震帶的一部分；且又因地質構造脆弱、地形陡峭，進而成為發生複合型災害高頻率之國家地區。其中崩塌 (landslide) 災害屬邊坡斜面上土體移動之現象，其發生機制係因斜面上土體受重力或事件使剪應力額外增加，致使邊坡抗剪強度相對降底而失去平衡，導致邊坡土體產生滑動現象(行政院農業委員會水土保持局 2005)。近年來在全球暖化氣候異常的影響下，水文極端現象明顯，受災範圍與程度均遠較過去為烈，也讓台灣成為全世界崩塌災害潛勢最高的國家之一。

現行坡地災害防減災工作中，及時且準確的發佈土石流紅黃警戒是保衛民眾生命財產安全的重要措施。因此藉由分析過去崩塌區域之動態變化情形建立預警模式，以有效而快速方式評估大區域範圍之潛勢概況，是值得投入資源研究的重要工作。有鑑於歷年山區大規模土石滑落與崩塌事件愈趨頻繁，實有必要瞭解台灣地區易發生崩塌之高潛勢區域，期可提高防減災能力並作為緊急應變時的決策依據。

世界各地的政府機構已發展各種措施來減輕和防止崩塌造成的損失，包括建築工程結構，規劃疏散路線和發布預警 (Choi and Cheung 2013, Highland and Bobrowsky 2008, Parise and Gunn 2007)。然而，所有這些措施都取決於辨識地景中具有使其易於崩塌的特徵的區域。崩塌潛勢模型 (Landslide Susceptibility Model, LSM) 透過計算網格資料每個網格的崩塌潛勢指標 (Landslide Susceptibility Index, LSI)，進行基於某些潛勢因子下該區域的易崩性預測 (Lee and Jones 2004, Liu, et al. 2015)。對於發展崩塌預警模式而言，首要任務便是建立準確的崩塌潛勢模型。

第二節 崩塌潛勢指標與模型

崩塌潛勢模型的建置是分析已發生之歷史崩塌來推估該地區崩塌潛勢大小，已有許多文獻在探討各種建置方法和其表現 (Baum, et al. 2005, Fourniadis, et al. 2007, Glenn, et al. 2006, Godt, et al. 2008, Hong and Wan 2010, Hong, et al. 2006, Hong and Adler 2008, Kirschbaum, et al. 2009, Kirschbaum, et al. 2009, Liu, et al. 2015, Shahabi and Hashim 2015, Shou, et al. 2009)，這些方法可大致分為定值法和機率法兩大類 (李錫堤 2009)，其中定值法是需要詳盡的地質調查參數，再輔以力學的觀點針對小範圍特定區域進行準確的分析，如極限平衡計算的無限邊坡法，這類模型需要了解土壤和岩石的機力學性質和該斜坡發生崩

塌的機制 (Canli, et al. 2015)，而且通常僅適用於小區域或單個斜坡，因此它很難將這些模型的結果普遍用到更大的區域層級 (van Westen et al. 2008)。而機率法又可分為定性法和定量法兩種，前者主要以經驗或專家觀點主觀地對崩塌進行分析描述以產生分數或指標 (van Westen, et al. 2008)，這個方法受到專家對於潛勢因子經驗的主觀性限制，並且可能在不同專家間可能產生不一致的結果。後者則將崩塌的各種資訊、徵兆與原因量化，並使用各種統計方法，例如判別分析、邏輯斯回歸、神經網路分析和頻率比等，生成崩塌潛勢指標 (LSI) 的定量圖 (Lee and Pradhan 2006, Pardeshi, et al. 2013, Wu, et al. 2016)。此方法是較客觀，且可進行大範圍的分析。此外，地理資訊系統 (Geographic Information System, GIS) 通過在不同子圖層地圖的代數運算，例如數值高程模型 (Digital Elevation Model, DEM)，建立 LSI 地圖是一項相對容易的任務 (Abella and Van Westen 2007, Godt, et al. 2008, Shahabi and Hashim 2015)。

許多因素可能導致崩塌，這些潛勢因子包括諸如地表的地貌性質 (例如，坡度，坡向，曲率)，地表下土壤和岩石的性質，土地利用和土地覆蓋狀況，植被覆蓋，與地質結構的距離，排水密度和誘發因子，像是強降雨或地震 (Costanzo, et al. 2012)。森林砍伐和都市化化等人類活動也會加劇崩塌問題 (Glade 2003, Reichenbach, et al. 2014)。

Koukis and Ziourkas (1991) 針對曾應用於崩塌潛勢分析之各種因子，進行全面性的總覽與探討，整理出大約有 64 種因子直接與崩塌發生有關。然而，部分因子並非相互獨立、部分因子無法明確量化、部分因子無法取得完整資料。為能建立可實際執行及通用的崩塌潛勢模式，本計畫參考(Liu and Luo 2016, Luo and Liu 2018)的論點，選取相關性較高，且較為普遍的因子。

第三節 紅色地圖

近年來高精度數值高程模型 (DEM) 和數值表面模型 (Digital Surface Model, DSM) 產製技術提昇而所需成本與時間又大幅下降，已成為科學研究與實務應用上普遍使用的資料來源，尤其是水土保持、土砂災害、國土規劃、防救災、環境監控與資源探勘等相關領域之重要參考依據。傳統的表現方法主要為高線圖、陰影圖或分層設色圖等圖資 (张玲, et al. 2014)，目的為展現高程、地形等資訊，然而在呈現微地形特徵時較常遺漏，導致重要資訊流失。透過地理資訊系統 (GIS) 結合色調飽和度值 (HSV) 的色彩模型建立的套疊於山影圖 (hill-shaded map) 上的彩色圖層，可以加強地圖上的地形特徵 (Favalli and Fornaciai 2017)。

紅色地圖即基於 HSV 彩色合成技術，紅色地圖為一種較新的地

形展現技術，源自 Yokoyama, et al. (2002) 提出的地形開闊度 (topographic openness) 概念，再利用與地形坡度之間的關係，搭配紅色色階與黑色色階來製作出紅色立體地圖 (Red Relief Image Map, RRIM) (Chiba, et al. 2008)。紅色在經驗上為人類視覺感受最豐富的色彩，能表現出絕佳的立體感，讓一般人可以直接圈繪出集水區邊界，也不易發生在等高線圖上圈繪集水區範圍結果不一致的狀況。

水土保持局以 2016 年及 2017 年創新研究計畫為基礎，開發出 H.O.S.T 地圖。此新型態的三維視覺化地形圖 (terrain map) 利用地形高程 (height)、開闊度 (openness)、地形 (terrain) 及坡度 (slope) 等概念，相較於一般地形圖，更能呈現地形的細部變化。而 H.O.S.T 地圖與紅色地圖最大之不同處，在於改良原計算方法，並加入高程資訊產製立體調色盤，除了表現出絕佳的立體感外，更可更直覺看出地表地形特徵，如所示圖 1-1。此技術已於 2018 年 6 月取得國內專利 (I627602 號)。




圖 1-1 於 BigGIS 上呈現之 H.O.S.T 地圖

紅色地圖的可視化 3D 視覺效果，允許從不同角度、方向檢視地圖，協助辨識地圖上的小型特徵，紅色地圖輔助空載光達 (Light Detection and Range, LiDAR) 的數值高程資料在判釋植生下的地質結構與地貌特徵 (Inomata, et al. 2017, Karatson, et al. 2016, Lin, et al. 2013)。紅色地圖影像的 3D 透視提供研究區域的虛擬實境，在 3D 視角中可以更清楚地看到斷層陡坎 (fault scarps) 和溝壑 (gullies)，而且顯示深層崩塌 (deep-seated landslides) 的地形特徵 (Chen, et al. 2015)。有鑑於紅色地圖在呈現地形特徵上的優勢，若能善加利用紅色地圖的資訊，或可提供額外的崩塌潛感因子，提升崩塌潛感模式的準確度。

第四節 計畫目標

水保局於 102 年至 107 年間執行「多尺度遙測空間資訊建置」與

「土砂災害空間資訊建置」計畫，已藉由多年期山坡地崩塌之歷史資料，建立研究區域之土砂災害預警模式，並針對特定颱風豪雨事件進行研究分析，藉以提出可能發生崩塌災害之相關參考資訊。以此土砂災害預警模式為基礎，本計畫應用深度學習架構，以紅色地圖、開闢度圖、坡度圖、岩性圖、坡向圖、累積通量圖等資料進行深度學習，建立一個應用人工智慧結合紅色地圖，創新的崩塌潛勢指標模型。具體目標條列如下：

- 一、蒐集與整理研究區域之崩塌潛勢因子、紅色地圖和崩塌目錄。
- 二、以卷積神經網路之深度學習架構，建構崩塌潛勢指標模式，並且使用3D視覺效果之紅色地圖加強模式的表現。
- 三、以一般深度學習神經網路，建構崩塌潛勢指標模式，與卷積神經網路建立之模式比較，分析卷積神經網路的3維模式表現，是否比1維之深度學習神經網路為佳。
- 四、分析結合不同因子組合之崩塌潛勢指標模式，辨識出預測崩塌潛勢指標的潛勢因子。

第二章 研究進度與內容

第一節 研究內容

本研究依據所設定之計畫目標，完成之工作項目與內容說明如下：

一、蒐集整理崩塌目錄、地質資料與前處理。

(一) 更新宜蘭太平山地區與花蓮和中地區之崩塌目錄至 2016 年。

(二) 取得研究區域之紅色地圖、坡度、坡向、岩性與累積通量地圖。

(三) 坡向與岩性資料的編碼處理。

(四) 切割大區域影像為 56*56 之影像，符合訓練影像之大小。

二、建立人工智慧之影像辨識模型與分析。

(一) 測試不同深度之 CloudNet 架構。

(二) 針對崩塌區域與非崩塌區域不平衡之資料比例測試不同的損失函數調整策略。

三、應用人工智慧與大數據方法建立崩塌潛勢模型。

(一) 建立與訓練不同深度之深度學習類神經網路模型。

(二) 與 CloudNet 架構訓練之模型結果比較。

四、分析不同特徵因子優化崩塌潛勢模型的效果。

- (一) 以坡度、坡向、累積通量、岩性、數值高程與紅色地圖等 6 個潛勢因子建立 57 種崩塌潛勢模式。
- (二) 最佳的因子組合模式進行 LSI 預估表現分析。
- (三) 各因子組合模式進行消融分析。

第二節 研究進度

本計畫所訂定之工作進度，如表 2-1 所示。淡綠色框為預定進度期程，淡藍色框為已完成進度期程，並標示完成百分比。

表 2-1 完成工作進度表

研究項目		研究期程(月份)		108 年度											
		1	2	3	4	5	6	7	8	9	10	11	12		
一、蒐集整理崩塌目錄、地質資料與前處理															
1	研究區域崩塌目錄與基本資料蒐集			100%											
2	研究區域紅色地圖資料蒐集				100%										
二、建立人工智慧之影像辨識模型與分析															
1	修改 Cloudnet 模式建立 LSI 分析模型			100%											
2	建立不平衡資料之損失函數權重調整模式				100%										
3	測試模型 LSI 分析結果				100%										
三、應用人工智慧與大數據方法建立崩塌潛勢模型															
1	建立其他深度學習模型進行 LSI 分析			100%											
2	測試模型 LSI 分析結果				100%										
四、分析不同特徵因子優化崩塌潛勢模型的效果															
1	使用最佳的模型測試紅色地圖加入模型的效果				100%										
2	分析不同潛釋因子組合對於模型訓練的影響			100%											
提送報告						期 初			期 中			期 末	成 果		
審查會議						期 初							成 果		
研討會						TGA	ICEO &SI								
預定研究進度百分比(%)				15	30	40	50	60	70	80	85	95	100		

第三章 研究區域與材料

第一節 研究區域

因為要進行崩塌潛勢指標之訓練，需挑選易受崩塌災害威脅之地區為研究區域，依此原則選定宜蘭太平山區域與花蓮和中社區為研究區域，分述如下：

一、宜蘭太平山區域

宜蘭位於台灣的東北部（圖 3-1），面積約 400 平方公里。沿海地區海拔 10 至 100 米，中部山區海拔約 2000 米。在迎風面常常因颱風侵襲，造成極端降水事件，引發許多崩塌，研究區內的崩塌總面積約為 3 平方公里。




圖 3-1 宜蘭太平山地區位置圖

二、花蓮和中社區

和中社區位於花蓮縣秀林鄉和平村。民國 101 年 6 月 10 日花蓮地區，發生規模 6.5 之地震；另於 15 日再發生一日 7、8 震的地震群，係於凌晨 0 點 15 分發生規模 5.4 地震，隨後又接連密集發生 77 起餘震，其規模都在 3~4 左右皆為淺層地震。民國 101 年 8 月 2 日蘇拉颱風從花蓮地區登陸，其所挾帶之強降雨量，造成花蓮縣當日累積降雨已超過 300 mm (如圖 3-2)。其中花蓮和中地區累積至 8 月 2 日早上 8 時之有效雨量更高達 940 mm (如圖 3-3)，進而造成該地區堆積於山溝之土石溢流成災，並有大量巨石掩埋和中部落多數民宅，如圖 3-4 所示。

此外，水保局亦於事件後建議調整宜蘭及花蓮地區部分土石流潛勢溪流「警戒基準值」，如圖 3-5 所示；而和中該區發生土砂災害的無名野溪，也於民國 102 年公開為土石流潛勢溪流「花縣 DF166」。




圖 3-2 花蓮和中部落崩塌前累積雨量圖

資料來源：(行政院農業委員會水土保持局 2013)




圖 3-3 和中雨量站降雨組體圖

資料來源：(行政院農業委員會水土保持局 2013)



圖 3-4 101 年蘇拉颱風過後花蓮和中部落崩塌狀況

資料來源：(行政院農業委員會水土保持局 2013)




圖 3-5 受地震影響建議調整之土石流警戒基準值範圍圖

資料來源：(行政院農業委員會水土保持局 2013)

第二節 崩塌目錄

台灣位於歐亞大陸板塊與菲律賓板塊交界上，屬環太平洋地震帶的一部分，又因地質構造脆弱、地形陡峭，進而成為發生複合型災害

頻率相對高的地區。2009 年，莫拉克颱風暴風圈在 8 月 7 日到 9 日間接觸本島，僅在 61 小時的時間內，就為中南部帶來 2,500 mm 以上的極端降雨，造成人民生命與財產空前的損失。依據災後衛星及航照影像判釋，國有林地崩塌主要係因強烈降水，導致上游野溪的側向侵蝕或向源侵蝕，加之台灣山勢陡峻、水短流急，實為難以避免之自然災害；關於全球暖化與極端降雨關連性的一項研究也顯示，由於這些強烈降雨大多來自於颱風，因此規模更大、數量更多的摧毀性水災、土石流，未來勢必無可避免 (Liu and Chen 2009)。在各種調查與分析方法中，運用衛星遙測影像進行廣域崩塌地判釋與災害分析的工作，具有相當的優勢，亦是世界發展的趨勢。

本團隊過去曾於民國 99 年至 105 年執行農委會林務局委辦之「運用衛星影像於全島崩塌地判釋與災害分析」計畫，以「福爾摩沙二號衛星影像自動處理系統」(F-2 AIPS)(Liu 2006) 處理福衛二號影像 (Lin, et al. 2013)，再以「遙測影像崩塌及陰影區專家輔助圈繪系統」(ELSADS)，以一致的方式完成了全島崩塌地之判釋與分析 (行政院農業委員會林務局 2012, 行政院農業委員會林務局 2014, 行政院農業委員會林務局 2017)，建置長達 13 年 (2004 年至 2016 年) 台灣詳盡的地區型崩塌目錄，可以和選擇的潛勢因子進行擬合分析，建立崩塌潛勢指標模型。

第三節 崩塌潛勢因子

過去 LSM 使用過的潛勢因子，有些因子並不相互獨立；有些因子可以參數化，卻無法普遍被定量量測 (Koukis and Ziourkas 1991)。所以為了建立一個崩塌潛勢的實用模型，過去的研究報告建議，選擇的潛勢因子應該可以在各個地區皆能普遍獲得和適用 (Liu, et al. 2004)。從對 1986 年至 2007 年期間的 145 項研究的回顧中，Süzen and Kaya (2012) 總結出最具影響力的自然因素是岩性，坡度，土地利用/土地覆蓋，排水距離因子和坡向。由於現有的土地利用/土地覆蓋資料有一類就是崩塌，因為高度的自我相關，所以土地利用/土地覆蓋的參數並不適合包含在我們分析的潛勢因子中。另外，累積通量值被證實，放入崩塌潛勢模式中，可比排水距離因子提升預測的正確性 (Liu, et al. 2015)。另外，本研究中並沒有考慮誘發因子 (地震和降雨)，希望能將問題單純化，只著重在發生崩塌的地理本質。所以本研究選擇坡度、坡向、岩性和累積通量值作為建立標準 LSM 的四個主要潛勢因素。

本研究採用崩塌潛勢分析方法，利用坡度、坡向、岩性、累積通量值等四種因子，配合民國 99 年梅姬颱風事件前之崩塌地判釋分布圖，以進行崩塌密度及權重計算；並利用自行開發之「崩塌分析系統 (landslide analysis system)」進行分析計算，以下說明以宜蘭太平山區域為例。

一、坡度因子計算

坡度因子代表坡地陡峭的指標因子，為直接影響邊坡穩定之重要指標。根據水土保持技術規範第二十三條指出，山坡地坡度係指一坵塊土地之平均傾斜比；而坡度可分為以下七級，如表 3-1 所示。然而，計畫中為詳細考量坡度變化所造成之影響，則是將坡度由 0° 至 90° ，依據每 1° 進行分級劃分為 90 個區間範圍。

依據各坡度區間範圍內所發生之實際崩塌面積，進行崩塌密度計算，推估得各分級所代表之評分值，如圖 3-6 所示；綠色直方圖代表不同坡度值範圍占研究區域總面積之百分比，而紅色直方圖代表不同坡度值範圍之崩塌評分值。再針對坡度分布條件，給定相對應的評分值，如圖 3-7 所示。由圖 3-6 可知，坡度愈大，評分值隨之增加；而於坡度大於 60° 後，該評分值開始有減小之趨勢，此乃因部分坡度較陡之坡面，可能為質地較為堅硬之岩性所組成，故曾發生崩塌的機率較低。

表 3-1 水土保持技術規範之坡度分級

坡度級別	級序	坡度(S)範圍	
一級坡	1	$S \leq 5\%$	$S \leq 3.2^\circ$
二級坡	2	$5\% < S \leq 15\%$	$3.2^\circ < S \leq 9.5^\circ$
三級坡	3	$15\% < S \leq 30\%$	$9.5^\circ < S \leq 18.6^\circ$
四級坡	4	$30\% < S \leq 40\%$	$18.6^\circ < S \leq 24.2^\circ$
五級坡	5	$40\% < S \leq 55\%$	$24.2^\circ < S \leq 32^\circ$
六級坡	6	$55\% < S \leq 100\%$	$32^\circ < S \leq 45^\circ$
七級坡	7	$S > 100\%$	$S > 45^\circ$




圖 3-6 坡度因子評分值

資料來源：(Liu, et al. 2015)




圖 3-7 坡度因子評分之分布圖

資料來源：(Liu, et al. 2015)

二、坡向因子計算

坡向因子代表坡地之面相指標因子，亦為直接影響邊坡穩定之重要指標；將坡向依據正北為 0° ，以順時針方向繞至 360° 方位範圍，每 4° 進行分級，據此評估不同方位角之崩塌情形。而後針對各坡向區間範圍內所發生之實際崩塌面積，進行崩塌密度計算，推估得各分級所代表之評分值，如圖 3-8 所示；綠色直方圖顯示不同坡向值範圍占研究區域總面積之百分比，而紅色直方圖顯示不同坡向值範圍之崩塌評分值。最後再針對坡向分布條件，給定相對應評估值，如圖 3-9 所

示。坡向因子可大致反應受氣象因素對坡地之影響程度。由氣象觀點分析，台灣夏秋兩季盛行南風與西南風；而颱風多由東、東南或南方海域往西北及北方向行走。由圖 3-8 之坡向因子評分結果可知，發生崩塌之坡向主要是集中於東南、南、以及西南等三個方向，乃因颱風行進路徑與西南氣流，影響降雨分布。




圖 3-8 坡向因子評分值

資料來源：(Liu, et al. 2015)




圖 3-9 坡向因子評分之分布圖

資料來源：(Liu, et al. 2015)

三、岩性因子計算

採用中央地調所公布的五萬分之一地質圖，以進行研究區域之地質類別分級；而於本範例區內所包含之岩性型態，如表 3-2 所示。依據各岩性類別範圍內所發生之實際崩塌面積，進行崩塌密度計算，推估得各分級所代表之評分值，如圖 3-10 所示；綠色直方圖代表不同岩性範圍占研究區域總面積之百分比，而紅色直方圖代表不同岩性範圍之崩塌評分值。再針對岩性分布條件，給定相對應的評估值，如圖 3-11 所示。

表 3-2 研究區域之岩性分類

分類	型態
1	板岩偶夾變質砂岩
2	礫石、砂、泥
3	變質砂岩
4	硬頁岩偶夾變質砂岩
5	變質砂岩偶夾板岩
6	片岩
7	板岩
8	硬頁岩
9	變質砂岩偶夾硬頁岩
10	滑動岩體或塊石
11	礫石層




圖 3-10 岩性因子評分值

資料來源：(Liu, et al. 2015)




圖 3-11 岩性因子評分之分布圖

資料來源：(Liu, et al. 2015)

由圖 3-10 之岩性因子評分值可知，分數較高的岩性種類為板岩、偶夾變質砂岩、礫石/砂/泥、硬頁岩偶夾變質砂岩、板岩等。本研究區大致位在中央山脈西翼及脊梁山脈地質區，該地質區內大部分的沉積物是深灰或灰黑色劈理良好的硬頁岩、板岩、以及千枚岩；亦即為經過變堅或變質的泥質岩石。泥質岩在西部以硬頁岩為主，向東漸漸變成板岩或千枚岩。頁岩於形成時會整齊排列，成一薄狀之頁理面，頁理面平滑、抗剪力低，遇水易漸崩解成土，易發生滑動與剝落現象；而砂、頁岩互層剪力低，遇水易發生層面滑動現象。

四、累積通量值因子計算

依據各累積通量值區間範圍內所發生之實際崩塌面積，進行崩塌密度計算，推估得各分級所代表之評分值，如圖 3-12 所示；綠色直方圖代表不同累積通量值範圍占研究區域總面積之百分比，而紅色直方圖代表不同流量累積值範圍之崩塌評分值。再針對流量累積值分布條件，給定相對應的評估值，如圖 3-12 所示。

累積通量值主要可反應降雨逕流之匯集情況，由圖 3-13 之評分結果可知，依據地表逕流之流況，流量累積值由山脊坡面開始向下游持續累加，而位於中上游之低級序河川，評分值隨流量累積值增加而逐漸上升，此乃因坡面上游累積足夠之地表逕流量，易導致地表沖蝕而發生崩塌。此外，中下游高級序之河川，其所反應之流量累積值較大；然而因地形地勢上較為低平，因此發生崩塌之機率反而較小。而流量累積最大值處發生評分值突增的情況發生，係由於該流量累積值分區範圍極小，而該範圍亦曾發生過崩塌，因而造成評分值變大，此乃統計分析上之問題。




圖 3-12 累積通量因子評分值

資料來源：(Liu, et al. 2015)




圖 3-13 累積通量因子評分之分布圖

資料來源：(Liu, et al. 2015)

五、紅色地圖

使用水土保持局技術研究小組提供的紅色地圖製作工具，載入自

水土保持局申請之 5 公尺數值高程模型資料，使用預設值設定窗罩半徑 20、對比度 10，產製 5 公尺解析度之紅色地圖，並且套疊研究區域之 Shape 檔，取出研究區域之紅色地圖資料（圖 3-14）提供分析。




圖 3-14 宜蘭太平山研究區域紅色地圖

第四節 深度學習方法

深度學習可以應用在非常多的領域上，協助電腦理解影像、聲音和文字等資料 (Alom, et al. 2017, Deng, et al. 2017, Liu, et al. 2017, Nagpal, et al. 2015, Ravì, et al. 2017)。目前的技術透過多層級的人工神經網路，能夠讓電腦如同人類一般針對複雜的情況進行觀察學習並反應。人工神經網路 (artificial neural network) 是一種模仿生物神經網

路之運算模型，使用大量的人工神經元聯結進行計算。圖 3-15 為類神經網路運算模型的範例，包含了輸入層、隱藏層與輸出層。類神經網路結構中的最小物件為節點(Node)，一個節點擁有四個元素：輸入(input)、權重(weight)、偏差(bias)、啟動函數(activation function)。每個輸入都有一個權重 w ，這些權重就會組成該層的權重矩陣(weight matrix)，每個輸入乘上對應的權重 w 加總後再加上 bias，再經過啟動函數 f ，成為這個節點的輸出，這些輸出會傳遞到下一層，直到最後的輸出層為止。




圖 3-15 類神經網路運算模型的範例

資料來源：<http://neuralnetworksanddeeplearning.com/chap5.html>

一、啟動函數 (activation function)

目前常用的啟動函數有 Relu 以及 Softmax，以下針對這兩個函式

進行介紹。

(一) Relu 為一種仿生物學原理的非線性數學函數，當神經元受到一定程度的刺激時才會有反應，可將類神經網路中的 node 視做神經元，當 node 的輸出 x 小於 0 時則輸出 0，此時這個 node 則視為不活躍而不參與更新，能夠有效降低梯度爆炸和梯度消失的問題。

$$f(x) = \max(0, x) \quad (1)$$

(二) Softmax 為一種機率函數，表達 K 個輸出中何者的機率最大。例如 [1,2,3,4,1,2,3] 對應的 Softmax 函數的值為 [0.024, 0.064, 0.175, 0.475, 0.024, 0.064, 0.175]，可以看到第四個位置數值 4 為最大 0.475，這個函數的意義上為對向量進行歸一化，凸顯其中最大的值並抑制遠低於最大值的其他分量

$$P(y = j|\mathbf{x}) = \frac{e^{\mathbf{x}^T \mathbf{w}_j}}{\sum_{k=1}^K e^{\mathbf{x}^T \mathbf{w}_k}} \quad (2)$$

訓練神經網路的主要步驟包括：1.決定輸入及輸出資料，2.建立網路模型 (function set)，3.從網路模型中找到最佳解。若要將上述之關聯法則修改為深度學習架構亦可依照這三個步驟進行。首先在輸入資料的準備上，可先做一次正規化 (normalization) 前處理，避免因為各類型資料分佈差異造成網路訓練時不易。輸出層則可預先將訓練資料的判斷結果分類，對每一類別給予一特定數字編號。最後是建立網

路模型，亦即決定層數以及每層的節點數。在訓練的同時需要以自身之訓練集進行驗證 (evaluation)，最終才是使用純測試集（不在訓練資料中）進行測試 (pure testing)。

從網路模型中找到最佳解的過程，可以理解為將輸入值透過一連串的函數運算，以求得預期中的輸出值。在訓練之初，網路中所有的權重參數都是隨機產生的，因此輸出值與目標會有誤差 (error)。訓練過程中會將此誤差值量化為誤差函數 (error function)，目標便是使此誤差函數最小化，其中最常使用的方法是梯度下降法 (gradient descent) 作為權重更新的機制。圖 3-16 為梯度下降法的示意圖，假設有一個誤差函數 f ，代入類神經網路的輸出 x 後可以得到一個 error 值 $f(x)$ ，更新的目標是盡可能縮小 $f(x)$ 的值讓類神經網路跟正確答案的差距達最小，所以對 x 做微分得到該點的梯度值，再將梯度值丟入最佳化函數 (optimizers function) 來決定每個 node 權重的更新數值。經過一定次數的更新後整個網路的輸出會朝著誤差函數的最低點移動。誤差函數和最佳化函數的種類則依照類神經網路的用途而定。




圖 3-16 Gradient descent 範例

資料來源：http://www.yaldex.com/game-development/1592730043_ch18_lev1sec4.html

二、梯度下降法 (gradient descent)

梯度下降法有以下幾種更新方法：

(一) 批次梯度下降法 (batch gradient descent) 為梯度下降法最初的方法，batch 為一組資料的意思，假設訓練集的資料有 N 筆，則將 N 筆的資料視為一組，將 N 筆資料的誤差算出平均後再更新網路一次，這個方法通常可以得到全局最佳解。圖 3-17 為收斂曲線的示意圖，會有一個比較平滑且穩定的更新曲線。優點是可以找到全域最佳解，缺點是當訓練資料集變大時訓練的速度就會變的緩慢。




圖 3-17 批次梯度下降法收斂曲線示意圖

資料來源：<https://www.itread01.com/content/1546601072.html>

(二) 隨機梯度下降法 (stochastic gradient descent) 解決了批次梯度下降法訓練過慢的問題，隨機梯度下降法只看一筆資料就進行更新，如果訓練資料集很大(數十萬或數百萬)，訓練其中的幾千或幾萬筆測資就能達到最佳解，總體而言可以不用疊代整個訓練集太多次就可以得到結果。雖然速度較快，但缺點是準確率可能會比批次梯度下降法來得不好，因為每次更新的方向可能不是全局最佳解，如圖 3-18 所示，X 是出

發點，紅色的箭頭指向的位置是終點，隨機梯度下降法在更新的过程中顯得比較雜亂無方向，最後的位置也距離中心點有一段距離。




圖 3-18 隨機梯度下降法收斂曲線示意圖

資料來源：<https://www.itread01.com/content/1546601072.html>

三、訓練常見問題

在網路訓練時最常見的問題是梯度消失 (vanishing gradient)、梯度爆炸 (exploding gradient) 以及過度擬合 (overfitting)，以下針對此三個問題進行說明：

(一) 梯度消失(vanishing gradient)：圖 3-19 的情況為各個隱藏層(hidden layer) 在訓練過程中權重參數變動幅度的過程，縱軸為變動幅度，橫軸代表訓練的次數。Hidden layer1 在圖中為藍線代表類神經網路中的第一層，Hidden layer4 在圖中為綠線代表類神經網路中的最後一層。從圖 3-19 中可以觀察到隨著訓練次數增加，Hidden layer1 的更新幅度變的很小，而 Hidden layer4 的更新則維持一定的幅度，造成離 input 較近且影響力較高的 Hidden layer1 學習的結果較差，甚至可能發生更新幅度趨近於 0 而不更新的狀況發生，導致 Hidden layer1 不學習，造成類神經網路整體的準確率無法提升，造成的原因是由於更新使用 gradient descent 的方法，更新量會由輸出慢慢往回推往輸入，而每層 layer 只盡量抓取自己可以更新的幅度，而不是合理分配每層的更新幅度。常見的解決方法是將類神經網路做逐層訓練，每新加一層隱含層時會繼承以訓練的權重。




圖 3-19 訓練過程中權重參數變動幅度的過程

資料來源：<https://blog.csdn.net/yejingtao703/article/details/793502>

87

(二) 梯度爆炸 (exploding gradient): 通常是因為 node 的權重更新後大於 1 使得輸入越來越大, 為了要平衡輸出常常影響其他 node 權重小於 -1, 造成輸入在各個 layer 或 node 間的變化太大, 使得整體網路不穩定。解決方法是加入 Batch Normalized layer (BN layer), BN layer 會對輸入做正規化, 如圖 3-20 所示, 避免各層之間傳遞的訊息隨著類神經網路加深而發生數量級太小或太大的狀況發生, 增加類神經網路的穩定度。




圖 3-20 在輸入層加入 batch normalized layer

資料來源：<https://wiki.tum.de/display/lfdv/Batch+Normalization>

(三) 過度擬合 (overfitting): 所謂 overfitting 指的就是過度訓練，意思就是說機器學習所學到的假設 (hypothesis) 過度貼近訓練資料，而導致和測試資料的誤差值變得更大，通常在類神經網路結構太大太深或是訓練資料無法分析的狀況下，導致類神經網路單純硬記訓練資料而不是產出一個可普遍表達的函數來判斷輸出，進而使判斷測試資料的能力變差。要解決 overfitting 的問題大致上有以下方法：(1) 下修類神經網路的複雜度，使用較少的 node 來訓練，這樣的可以避免模型直接記憶訓練資料。(2) 在損失函數中加入正則項

(Regularization)，例如下面公式為 L2 regularization 的正則項，它透過懲罰損失函數，達到避免 overfitting 的效果。

$$\text{Cost function} = \text{Loss} + \frac{\lambda}{2m} * \sum ||w||^2 \quad (1)$$

(3) 加入 dropout。dropout 的功能為每次訓練時，每層的 node 都有機會失效一定的比例，如圖 3-21 所示，藉此增加訓練集的多樣性也避免類神經網路過度依賴特定的 node。




圖 3-21 使用 Drop out 之範例

資料來源：(Srivastava, et al. 2014)

四、卷積神經網路

卷積神經網路透過使用卷積核取代傳統神經網路的全連接層，使網路架構更適合用於影像處理之應用。卷積類神經網路的結構通常包含了卷積層 (convolution layer) 以及池化層 (max pooling layer)。其意義是將網路的權重矩陣以卷積相乘後，輸出特徵圖 (feature map)，而

池化層之功能是将卷積運算後的結果取其最大值。在 CNN 網路中上述步驟可以重複多次，以求達到所希望的成果。透過這些特性，CNN 可以達到以下優勢：

(一) 減少參數並且可以共用特徵：由於權重矩陣以卷積的方式呈現，相較於全連接網路的路徑減少了許多。也因為是使用卷積運算，同一個 feature map 可以共用於資料中的各個區塊，換言之若是要使用 CNN 辨識圖片中的特徵，則同一個 feature map 可以辨認出影像中具有相同特徵的位置（例如邊緣）。因為這樣的特性，可以減少參數的使用使網路的訓練更加有效。

(二) 支持縮放不變性：這個特性是由 max pooling 運算所達成，由於池化運算是取卷積計算後的最大值，類似高通運算 (high pass) 的結果。因此不論特徵大小，只要在設定的檢查範圍（例如 2x2 pixel）內都會被輸出，達到縮放不變性的效果。但是其支援的解析度尺度是根據池化層的大小而定，因此要避免解析度變化過於劇烈。

傳統的卷積類神經網路最後包含全連接層作為分類器，全卷積類神經網路 (Fully Convolutional Neural Network, FCN) 將全連接層改成全卷積層，如此，輸出的預測結果會是一個二維的 feature map 而不是 CNN 的一維 feature map。不僅可以達到對於輸入圖像中每個 pixel 的預測，也因為全卷積層比全連接層有更少的可訓練參數數量，

因而加快了整個 model 訓練的過程。

各個潛勢因子地圖與紅色地圖，具有影像特徵之資料，適用於使用 CNN 作為主要訓練的模型。卷積類神經網路自 1986 年提出以來已發展多年，在 2012 年的 ImageNet 圖像辨識分類比賽中，加拿大多倫多大學教授 Geoff Hinton 的研究團隊以 CNN 技術將圖片辨識率提高到 85%。CNN 著名的架構包含 Lenet (1986)、Alexnet (2012)、GoogleNet (2014) 以及 VGG (2014)。觀察這些架構可以發現，卷積層的使用都是由大而小，例如 googleNet 的第一個卷積層使用了 7x7 的卷積核，並逐步降低到尺寸為 3x3，其意義為先取出概略的特徵再逐步往細節辨識。Googlenet 亦證明了隨著網路深度增加且使用更多的卷積層可以得到更好的辨識成果。觀察 GoogleNet 的設計 (Szegedy, et al. 2015)，在網路的後段有一特別的設計，稱為 inception layer (圖 3-22(a)) (He, et al. 2015)，這個概念是來自於 Network in Network，亦即在每一層傳遞時不單只傳遞一種計算的結果，而是採用各種大小不同的卷積核，分別計算多種特徵後拼接成新的一層，其架構如圖 3-22(b) 所示。googlenet 的架構中含有 Convolution 層 (藍色區)、Pooling 層 (紅色區)，綠色區塊是用來拼接平行的 inception layer，最後做分類輸出的則是使用 Softmax 層。




圖 3-22 GoolgleNet 架構與後段的 inception layer

資料來源：(He, et al. 2015)

Deeplabv3+架構為 Google 在語意分割上最新的架構，分成兩個部份，其特徵擷取的架構採用改良的 Xception (Ronneberger, et al. 2015) 架構，是一個基於 FCN 的架構。與此架構的輸出端連結的是空洞空間金字塔池化 (Atrous Spatial Pyramid Pooling, ASPP) 模組，ASPP 由空間金字塔池化 (Spatial Pyramid Polling, SPP) (Huang, et al. 2016) 加上空洞卷積 (atrous convolution) (Zhan, et al. 2017) 而成。ASPP 概念

已經被證明對於分辨不同解析度的物體有不錯的效果 (Drönner, et al. 2018)。Deeplabv3+利用 ASPP 的特性，提高對於相同物件不同大小的辨識能力。在將 feature map 還原回原本輸入圖片的大小的階段。Deeplabv3+將淺層的 feature map 與深層的 feature map 相結合，藉以回復損失的邊界資訊。最後利用上採樣，將 feature map 回復到與輸入層相同大小。

第四章 研究方法與步驟

本研究將依選定的 2 處研究區域，蒐集與彙整 2004~2016 年 13 年之崩塌目錄為深度學習之訓練目標 (label data)，以紅色地圖、坡度圖、坡向圖、岩性圖與累積通量圖為訓練資料，訓練深度學習模式之參數，運算適合輸入之潛勢因子資料的崩塌發生之後設機率 (posterior probability)，作為崩塌潛勢因子的預測值，並以累積崩塌百分比 (cumulative percentage of landslide occurrence, CPOLO) 對 LSI 等級繪圖，生成成功率曲線，評估深度學習模式的表現，圖 4-1 為測試流程步驟：




圖 4-1 深度學習測試步驟

以下各節將詳細說明各步驟之方法。

第一節 準備資料

因為以全卷積類神經網路為主要模式，目前 FCN 的輸入資料，可接受多波段之 tiff 檔案，所以取得之潛勢因子、紅色地圖的 RGB 波段數值，將以多波段之方式合併於 tiff 檔案中，目前資料解析度為 5 平方公尺，宜蘭太平山區域資料影像大小為 4982 x 4775 之影像；花

蓮和中地區之資料影像大小為 4568 x 2791 之影像。

因為深度學習訓練演算法的特性，單一大影像不利於更新模式參數。多批次更新模式參數，比單次大資料量運算後更新參數更有效率(見第三章 SGD 的說明)，而且深度學習訓練的參數很多，以第二章第 4 節介紹之 Deeplab 3+ 架構，參數量就高達 5 仟多萬個，所以可以使用較小的影像尺寸，避免造成電腦系統資源耗盡，無法訓練。目前預備做深度學習之影像，將切割為 56 x 56，以目前資料解析度 5 公尺的影像，崩塌在影像中的尺度也不至於太小。另外，本研究在使用卷積神經網路訓練時，也將使用影像擴增技術 (Data augmentation)，將輸入之影像長寬皆重疊 33 個像素、上下左右翻轉與順逆時針 10° 的旋轉。

深度學習之訓練，需將資料分為訓練資料 (training data) 與驗證資料 (validation data)，驗證資料在訓練的過程中，並無加入適配模式參數的過程，而僅在每一批次訓練之後，進行損失函數和正確率的運算，驗證模式是否 over-fitting。驗證資料是由全部切割的未重疊之影像，隨機選擇 10% 做為驗證資料，其餘未與驗證資料重疊之影像，作為訓練資料。切分為訓練資料與驗證資料之影像，其崩塌分佈與原資料分佈一致 (圖 4-2)，驗證資料與實際的崩塌分佈一致，可讓本研究訓練驗證好的模式，使用於實際目標地區的崩塌潛勢預估，不致於

落差太大。花蓮和中地區的崩塌分佈狀況，也類似於宜蘭地區，由於它切割後的影像數量只有宜蘭區域的 1/3，資料量太少，所以目前只用來測試宜蘭地區資料訓練出來的模式，是否可普遍使用於其他區域。




圖 4-2 模式訓練資料之崩塌像素直方圖

(a)(b)(c) 為宜蘭研究區域崩塌目錄影像之崩塌像素直方圖，(a) 為總資料；(b) 為訓練資料 (33 像素重疊)；(c) 為驗證資料。(d) 為花蓮和中研究區域之崩塌像素直方圖。

第二節 模式設計

紅色地圖是由坡度與開闊度，透過紅色與黑色色階呈現出來，在資料的特徵工程中，它已是透過專家意見，做了特徵轉換，在平面空間影像中反映出微地形。人工智慧中的影像視覺，可輔助偵測與辨識影像中的地形特徵，目前影像視覺最有效的辨識方法，即為卷積類神經網路架構。

本研究以過去本團隊於衛星影像雲辨識之深度學習模式 CloudNet 之底層技術 (Liu, et al. 2019)，測試不同模式對於擬合潛勢因子估計崩塌潛勢指標的表現。CloudNet 架構如圖 4-3 所示，結合 Atrous Spatial Pyramid Pooling (ASPP) 和 Residual learning 的優點，可以在卷積神經網路中，保留空間資訊。過去在雲的辨識訓練中，ASPP 的寬度為 7，網路深度為 12 時表現最佳，本研究之崩塌潛勢指標模式訓練，除了紅色地圖外，會結合潛勢因子 (坡度、坡向、累積通量與岩性) 進行訓練，不同的網路深度可能會影響訓練表現。




圖 4-3 CloudNet 架構圖

資料來源：(Liu, et al. 2019)

除了全卷積類神經網路的架構，由於崩塌潛勢因子資料，累積通量因子，已將空間的資訊考慮進來，考慮全卷積類神經網路在特徵邊緣，仍有遺失空間細節的缺點，所以本研究也將測試深度類神經網路 (Deep Neural Network, DNN) 架構 (圖 3-15)，期望能更全面的考量，研究出分析崩塌潛勢因子的最佳模式架構。

第三節 模式訓練與驗證

深度學習之訓練方式，如第二章所述，將透過隨機梯度下降法和反向傳播演算法，訓練模式之權重。在每一回訓練更新參數後，運算訓練資料與驗證資料之損失 (loss) 與驗證指標 (metrics)。模式將訓

練 200 回，並取模式估計驗證資料之崩塌潛勢指標，進行驗證指標的計算，並以能評估出最佳之驗證指標的模式參數，作為最佳模式參數，再用以進行比較模式間的崩塌潛勢指標的預估表現。

一、損失函數

本研究使用的損失函數為 softmax cross entropy，它是深度學習中，對於影像分類常用的損失函數。然而因為崩塌區域與非崩塌區域資料的不平衡，見圖 4-2，大多數影像包含的崩塌區域較小。對於小物件在影像上的分類，在全卷積類神經網路 (full convolution neural network, FCN) 的訓練中，將會影響最後的辨識準確率，在經過 Loss 的調整後，可增加模式的辨識準確度 (Kampffmeyer, et al. 2016)。本研究參考該篇研究使用的中位數頻率平衡 (median frequency balancing) 調整損失函數，由於本研究僅有 2 個類別 (崩塌與非崩塌)，所以損失函數的權重調整公式，將簡化為

$$w_l = \frac{f_n}{f_l} \quad (2)$$

$$w_n = 1 \quad (3)$$

其中 w_n 、 w_l 分別為非崩塌像素與崩塌像素的損失權重， f_n 、 f_l 則分別為為該訓練批次非崩塌像素與崩塌像素的數量。上述的方法，也就是以增加崩塌像素的損失權重來補償訓練資料不平衡的狀況；另外，另一篇研究提出 Focal loss 作為損失函數，它以降低優勢背景

影像資料損失權重的方式，增加目標物件的辨識正確率 (Lin, et al. 2017)。本研究將參考此網站 <https://github.com/umbertogriffo/focal-loss-keras>，實作 Focal loss 損失函數。

二、驗證指標

進行影像分類的驗證指標是辨識的正確率 (accuracy)，然而本研究主要進行崩塌潛勢指標模式的建立，並且估計各區域的崩塌潛勢指標，並非實際辨識該區域是否為崩塌區域，而是預估該區域可能發生崩塌的機率。所以評估崩塌潛勢指標模式的優劣，需要使用其他的指標。

接收者操作特徵曲線 (Receiver Operating Characteristic curve，ROC 曲線)，它用與描述與比較診斷技術和診斷演算法的表現 (Hanley and McNeil 1983)，曲線的橫軸是 1－真陰性率 (偽陽性率)，縱軸是真陽性率，這 2 個比率在進行診斷或辨識時，真陰性率和真陽性率通常是 Trade-off 的關係，當調低判斷的閾值時，真陽性率 (也就是偵測率) 將會提高，但可能會增加誤判，也就是提高偽陽性率，使得整體正確率並不一定提高。一般會以曲面下面積 (Area Under Curve，AUC) 為指標判斷預測模式的 ROC 曲線的優劣，ROC 曲線下面積在 Python 深度學習套件 Tensorflow 中，已有實作，所以直接呼叫

Tensorflow 的 `tf.metrics.auc` 函數，用於訓練過程，評估當下模式參數的表現，並以訓練 200 次後 ROC 曲線下面積最高的為最佳的模式參數，進行模式表現評估。




圖 4-4 接受者操作特徵 (ROC) 曲線

第四節 崩塌潛勢指標預測表現

如本章第一節所述，本研究將 2 研究區域之資料分為 3 組資料，其中驗證資料，除了在訓練時作為評估最佳模式參數的用途外，也用以比較模式間的表現；另外一組測試資料 (和中研究區域)，將以目前測試最佳之模式，估計崩塌潛勢指標，評估模式的普遍應用性。

為了定量評估 LSI 的性能，我們採用了累積崩塌百分比 (cumulative percentage of landslide occurrence, CPOLO) 對 LSI 等級繪圖，生成成功率曲線 (如圖 5-3) 以測量 LSI 的性能。成功率曲線是通過繪製 CPOLO 對 LSI 排名從高到低生成的圖表：曲線越陡峭，LSI 預測崩塌的能力越強 (Chung and Fabbri 2003, Frattini, et al. 2010, Oh and Lee 2010)。成功率曲線下的面積可用於評估 LSI 的總體預測準確度 (Oh and Lee 2010)。LSI 指標改善百分比 ρ 定義如下：

$$\rho \equiv \frac{CPOLO_{model1} - CPOLO_{model2}}{CPOLO_{model2}} \quad (4)$$

第五節 開發平台與深度學習模組

本研究的深度學習運算環境架設於裝有 nvidia Geforce RTX 2080 Ti 顯示卡的電腦主機中，顯示卡的 GPU 引擎可以支援機器學習的平行運算，加速訓練的進行。深度學習開發語言使用 Python，安裝深度學習套件 Keras 2.1.6，內建很多深度學習的模組，它呼叫的底層套件為 Tensorflow，它是由 Google 團隊開發的數值運算函式庫，目前環境安裝的版本為 1.13.1。

第五章 研究成果

本計畫蒐集彙整研究區域內之崩塌目錄、潛勢因子資料與紅色地圖，並建構一系列不同之神經網路架構，包括卷積類神經網路，以建立崩塌潛勢指標模型，利用紅色地圖的視覺化特徵與潛勢因子預測崩塌潛勢指標，分析不同潛勢因子組合對於崩塌潛勢指標的預估表現，進一步探討崩塌潛勢指標模型選擇的適當性。研究成果分述如下：

第一節 潛勢因子的編碼

一、岩性因子進行獨熱編碼處理 (one-hot encoding)

岩性是名目資料，在機器學習領域最常見的編碼處理是獨熱編碼 (Bishop 2006)，即將每個岩性類別編碼為 0 或 1，若該數值為 1，表示該像素屬於該類別。目前岩性有 15 個類別，所以將分為 15 個因子輸入模式做訓練。

此實驗使用的模式架構為寬度 7 深度 12 的 CloudNet 模式，訓練資料使用坡度 (Slope, S)、坡向 (Aspect, A)、累積通量 (Total Flux, TF) 和岩性 (Ethology, GM) 4 種因子，比較岩性因子原始資料 (GM) 與編碼後的岩性 (Ethology encoded, GME) 資料，進行深度學習訓練的結果。

將岩性編碼後訓練的模式評估的結果見圖 5-1(a) (實線 vs. 點線)，成功率曲線下面積提升了 4.06%




圖 5-1 資料編碼對 CloudNet 架構訓練後的模式表現

(a) 無數值高程的模式預估結果；(b) 加入數值高程資料的模式預估結果。

二、坡向因子進行正弦函數 (sin) 與餘弦函數 (cos) 的轉換

坡向的數值類似於週期性資料，角度的資料，可以由歐拉公式

(Stillwell 2010)，編碼為複數平面上單位圓圓周上的一個點 (圖 5-2)，公式如下：

$$e^{i\varphi} = \cos\varphi + i\sin\varphi \quad (5)$$




圖 5-2 複數平面上的單位圓

資料來源：https://zh.wikipedia.org/wiki/%E6%AC%A7%E6%8B%89%E5%85%AC%E5%BC%8F#/media/File:Euler's_formula.svg

經過餘弦函數編碼的坡向因子，在坡向 0 度與 180 度時數值分別為 1 和 -1，可表達坡向在南北向時的最大差異；而經過正弦函數編碼的坡向因子，在 90 與 270 度時分別為 1 和 -1，可呈現坡向在東西向時的最大差異。

此實驗同樣使用的模式架構為寬度 7 深度 12 的 CloudNet 模式，分別測試加數值高程與未加數值高程資料的結果：

(一) 未加數值高程 (Digital Elevation Model，DEM)

1. S + 坡向 (Aspect，A) + TF + GME
2. S + 編碼後的坡向 (Aspect Encoded，AE) + TF + GME

此測試結果可見圖 5-1(a) 的虛線與點線，編碼後的坡向，對於沒有數值高程因子組合的模式，並沒有幫助。

(二) 加數值高程為第 5 個潛勢因子

1. S + 坡向 (Aspect, A) + TF + GME + DEM

2. S + 編碼後的坡向 (Aspect Encoded, AE) + TF + GME + DEM

此測試結果可見圖 5-1(b)，在結合數值高程因子訓練的結果，其預估表現反而下降了 (虛線)，但若將坡向進行編碼，模式訓練的結果，使預估的表現提升了 7.63%。

由此節的測試結果來看，岩性因子和坡向因子的編碼，確實提升了模式預估的表現，但因子組合間的關係，會影響訓練深度學習模式的表現，將在潛勢因子組合小節進行探討，之後測試的岩性與坡向因子，皆作編碼處理。

第二節 損失權重調整

一、損失函式經過發生比率權重的調整 (frequency balancing) 可增加模式預估表現。

因為資料中未發生崩塌與曾發生崩塌區域比例相差很大 (約 28~35 倍), 在進行深度學習訓練時, 將不容易訓練到崩塌區域的特徵, 所以本研究將測試以下 2 種損失函數的權重調整方式

(一) Focal loss

(二) Frequency balancing

此實驗使用的模式架構為寬度 7 深度 12 的 CloudNet 模式, 5 種潛勢因子資料進行模式訓練 (見前一節)。

結果如圖 5-3, Focal loss (虛線) 與未調整損失函式 (點線) 所訓練出來的模式表現結果相似 (曲線下面積分別為 23.5 和 23.7)。而經過崩塌面積比率調整後的損失函數所訓練的模式, 其成功率曲線表現大大提升, 曲線下面積為 66.7。




圖 5-3 不同的損失函式權重方法對模式的預測表現

二、加乘損失函數權重可進一步提升模式預估LSI的表現。

測試加乘崩塌像素損失函數權重，調整後的公式如下：

$$w_l = x \frac{f_n}{f_l} \quad (6)$$

其中 w_l 為崩塌像素的損失權重， f_n 、 f_l 則分別為為該訓練批次非崩塌像素與崩塌像素的數量， x 為加乘倍數，測試的倍數為 1~15。

(一) 5 個潛勢因子資料

結果如圖 5-4，不管是宜蘭地區的驗證資料 (a) 還是和中地區的資料 (b)，在損失函數權重加乘至 15 倍的訓練下，模式預測結果的成功率曲線下面積可達到最高；ROC 曲線下面積在宜蘭地區的測試資料可維持在 0.85 以上，但在和中地區的資料，則微幅降低至 0.73。




圖 5-4 5 個潛勢因子加乘損失函數權重訓練的模式表現

(a) 宜蘭太平山區域測試資料預估結果；(b) 宜蘭太平山區域測試資料預估結果。

(二) 紅色地圖資料

僅使用紅色地圖資料訓練，在損失函數權重加乘至 15 倍時，仍可加強 LSI 預估成功率曲線下面積的表現，且 ROC 曲線下面積維持一定水平 (圖 5-5)。這顯示加乘至 15 倍是可以套用在此

地區資料的訓練，並不會受到模式使用的因子影響。




圖 5-5 紅色地圖加乘損失函數權重訓練的模式表現

(a) 宜蘭太平山區域測試資料預估結果；(b) 宜蘭太平山區域測試資料預估結果。

第三節 模式深度

一、以深度較深的CloudNet模式架構表現優於深度類神經網路與較淺的CloudNet架構。

此部份實驗測試了節點數量為 1024，隱藏層為 1、2 層的深度類神經網路 (DNN)，還有深度分為 3、6、9、12 層之 CloudNet 模式。結果顯示深度類神經網路的表現優於較淺之 CloudNet 模式，其曲線下面積超過 87，但是深度達 12 層的 CloudNet 所訓練的模式，其成功率曲線下面積可超過 90 (圖 5-6)。深度類神經網路 1 層加深至 2 層，訓練的參數已超過 100 萬 (表 5-1)，增加了近 40 倍，但成功率曲線下面積只由 87.0 提升至 87.3。CloudNet 架構深度由 3 層增加至 12 層，訓練的參數僅增加 4 倍，但預估表現可由 85.9 提升至 90.3。




圖 5-6 深度類神經網路與 CloudNet 崩塌潛勢指標模式表現

表 5-1 深度類神經網路與 CloudNet 架構訓練參數量與時間

模式	總參數量	待訓練參數量	訓練時間 (分鐘)
深度類神經網路			
1	27,650	25,602	65
2	1,081,346	1,077,250	121
CloudNet			
3	3,986	3,786	227
6	7,862	7,470	271
9	11,738	11,154	336
12	15,614	14,838	450

二、深度類神經網路的層數增加無法提升LSI的預估效果。

此部份實驗提升 DNN 的層數至第 7 層，8 層以上的 DNN 因電腦硬體的限制，無法訓練。結果見圖 5-7，提升至第 7 層其預估效果並無繼續提升。




圖 5-7 深度類神經網路對 LSM 的學習成效

第四節 潛勢因子組合

由前面 3 節的結果，已證實 CloudNet 架構結合潛勢因子，可以有效地訓練 LSI 模式，且成功率曲線下面積可以提升高達 96，為避免混淆，以下簡稱使用 CloudNet 架構訓練的 LSI 模式為卷積崩塌潛勢模式 (Convolutional Landslide Susceptibility Model, CLSM)。為進一步了解各因子對卷積崩塌潛勢模式訓練效果的影響，所以本節研究將以 5 種潛勢因子和紅色地圖資料，進行消融研究 (ablation study)，透過不同因子的組合，觀察這些因子對 LSI 模型預估表現的影響。

本研究收集有 5 種潛勢因子和紅色地圖資料，總共 6 種因子，取 2 種因子組合數 $C_2^6 = 15$ 、3 種因子組合數 $C_3^6 = 20$ 、4 種因子組合數 $C_4^6 = 15$ 、5 種因子組合數 $C_5^6 = 6$ 和 6 種因子組合數 1 種，共有 57 種組合，由這 57 種組合分別進行模式訓練，取得最佳的模型參數。並先以 ROC 曲線下面積，選擇較佳的組合進行分析。

一、6種潛勢因子同時考慮的卷積崩塌潛勢模式為最佳的模式。

圖 5-8 是 57 種因子組合不同卷積崩塌潛勢模式訓練後，預估宜蘭地區測試資料之 LSI，以 ROC 曲線下面積繪製成熱度圖 (heatmap)。垂直順序依各模式預估 LSI 的 ROC 曲線下面積排序，水平因子依該因子參與的模式中預估 LSI 的 ROC 曲線下面積 75 百分位數排序。由圖中可以發現，表現最佳模式是 6 種因子的模式，其次是沒有紅色地圖的 5 種因子模式。依水平排序的結果可以發現，岩性是區分崩塌與非崩塌很重要的因子，在含有紅色地圖模式中，其預估的 ROC 曲線下面積排序也在前面。




圖 5-8 57 種因子組合訓練模式後預測宜蘭太平山區域資料之 ROC 曲線下面積熱度圖

二、以和中地區的資料評估的最佳模式是含有累積通量、岩性和紅色地圖的模式。

圖 5-9 是 57 種因子組合不同卷積崩塌潛勢模式訓練後，預估花蓮和中地區資料之 LSI，以 ROC 曲線下面積繪製成熱度圖 (heatmap)。由圖中可以發現，表現最佳模式是累積通量、岩性和紅色地圖組成的模式，其次累積通量、岩性和坡向組成的模式。




圖 5-9 57 種因子組合訓練模式後預測花蓮和中區域資料之 ROC 曲線下面積熱度圖

三、5種因子組合中，含有累積通量的模式表現普遍較好，其他因子的重要性依次為岩性、坡向、坡度、數值高程與紅色地圖。

57 種因子組合並非每個組合都能成功訓練模式，排除未能成功訓練之模式之最大的 ROC 曲線下面積為 0.79，挑選 ROC 曲線下面積超過 0.80 的模式進行比較。圖 5-10 為 4 個因子模式 (白) 與 5 個因子模式 (黑) 的比較圖。ROC 曲線下面積超過 0.80 的模式已排除了沒有累積通量的模式，這表示含有累積通量的模式普遍較佳；由 (b)(c)(d)(f) 可以觀察到，含有岩性的 5 因子模式比沒有岩性的 4 因子模式的 ROC 曲線下面積有較大的提升；其他因子的重要性也可以由圖上 ROC 曲線下面積比較觀察到：(a) 坡向 > 坡度；(e) 數值高程 > 紅色地圖；(g) 坡向 > 數值高程；(h) 坡度 > 數值高程。




圖 5-10 4 因子模式與 5 因子模式因子重要性比較圖

(a)~(h) 4 個因子以底線相連標示於子圖標題上，第 5 個因子標示於 X 座標軸，X 為 4 因子的長條圖。

四、6 因子的卷積潛感模式可以提升區域性 LSI 預估的成功率曲線表現；3 因子的卷積潛感模式可讓模型的通用性較佳。

本節的研究結果發現，本研究取得的潛感因子，皆對建立卷積潛感模式有正向的影響，以宜蘭地區與和中地區測試資料檢驗，分別挑選出 6 因子模式和 3 因子模式（累積通量、岩性、紅色地圖）。2 個模

式預估 LSI 的表現見表 5-2，6 因子模式預估宜蘭地區測試資料 LSI 的 ROC 曲線下面積在 0.85，成功率曲線下面積可達 96.3；6 因子模式預估花蓮和中地區 LSI 的成功率曲線表現很好，但 ROC 曲線下面積降至 0.74，這表示 6 因子模式對花蓮和中地區的資料崩塌與非崩塌的區域的區隔，較不明顯。

3 因子模式雖然預估的成功率曲線表現雖然比 6 因子模式低，但其表現仍然很好，而且提升了預估花蓮和中地區 LSI 的 ROC 曲線下面積，此結果顯示 3 因子模式會有比較高的通用性。

表 5-2 最佳的卷積潛感模式預估 LSI 的表現

模式	ROC ^a	CPOLO ^b	前 1% ^c	前 10% ^c	前 20% ^c
6 因子模式					
宜蘭太平山	0.85	96.3	39.4%	92.6%	97.3%
花蓮和中	0.74	97.8	72.5%	97.0%	98.5%
3 因子模式					
宜蘭太平山	0.83	94.3	24.5%	84.5%	93.7%
花蓮和中	0.78	96.7	37.3%	95.1%	97.9%

a 該欄數值為接收者特徵操作曲線下面積 (AUC)

b 該欄數值為成功率曲線下面積

c 該欄數值為 LSI 排名下的累積崩塌百分比

第六章 結論及建議

本研究使用 6 種潛勢因子資料訓練卷積類神經網路 CloudNet 架構，建立的卷積崩塌潛勢模式，可應用於宜蘭地區與和中地區的崩塌潛勢指標的預估，而且在成功率曲線的表現，比 Luo and Liu (2018) 表現提升了不少，該篇研究提出新的 geomorphon 方法，以視線概念辨識地形元素，並且整合新的地理偵測器方法 (geographical detector method)，客觀地估計崩塌潛勢模式的權重，已可讓成功率曲線下面積由 80.0 提升至 86.5，但本研究採用紅色地圖結合潛勢因子的卷積崩塌潛勢模式，已提升成功率曲線下面積至 96.3，與 Luo and Liu (2018) 的研究比較，在前 1% 的 LSI 排名，LSI 指標改善百分比 ρ 為 480.0%；在前 10% 的 LSI 排名提升了 120.0%；在前 20% 的 LSI 排名提升了 53.5%。

表 6-1 最佳的卷積潛感模式預估與過去研究比較

模式	CPOLO ^b	前 1% ^c	前 10% ^c	前 20% ^c
宜蘭地區				
Liu et al. 2016	80.0	6.0%	42.0%	62.0%
Luo and Liu 2018	86.5	6.8%	42.1%	63.4%
卷積崩塌潛勢模式	96.3	39.4%	92.6%	97.3%
LSI 指標改善百分比 (ρ)		480.0%	120.0%	53.5%

a 該欄數值為接收者特徵操作曲線下面積 (AUC)

b 該欄數值為成功率曲線下面積

c 該欄數值為 LSI 排名下的累積崩塌百分比

本研究以發生比率權重調整損失函數，以加強對少數崩塌區域資料的訓練，並且提出損失函數權重加乘的方法，透過探索性的試驗 (trial test)，測得損失函數權重加乘至 15 倍有最佳的卷積崩塌潛勢模式訓練效果，而且是不受參與的因子和測試區域的影響。

本研究透過消融研究 (ablation study) 的方式，測試了 57 種不同因子組合的模式，發現模式中若有累積通量因子，會有較佳的表現。其他因子的重要性排序分別為岩性、坡向、坡度、數值高程與紅色地圖。然而，有些因子建立的 LSI 模式是有地域關係的，使得簡化的模式，通用性比較高。本研究建立的 3 因子卷積崩塌潛勢模式，由累積通量、岩性和紅色地圖組成，參數是由宜蘭太平山地區的資料所訓練，但模式測試的 ROC 曲線下面積比 6 因子的卷積崩塌潛勢模式來得高。

本研究的成果可結合水文、天氣成果可結合水文、氣象、以及地理資訊資料，將可作為一趨勢模型，用以預測崩塌災害發生之可能性，並據以評估所導致的危害與風險，例如可分析某區域是否有發生土石流的風險。本計畫所開發之深度學習架構，可將收集所得的大數據資料，自動建立崩塌潛感模式，預估崩塌災害發生的風險，降低人為主觀的介入，未來結合地理資訊系統，導入更加完善的資料輸入與模式評估的自動化流程，建立智慧防減災資訊平台。

參考文獻

1. 地質法，"地質法"，中華民國 99 年 12 月 8 日 中華民國 99。
2. 行政院農業委員會水土保持局，"水土保持應用手冊"，2005。
3. 行政院農業委員會水土保持局，"102 年多尺度遙測空間資訊資料建置及擴充維護計畫"，2013。
4. 行政院農業委員會林務局，"運用光學衛星影像於全島崩塌地判釋與災害分析(99-101 年)"，2012。
5. 行政院農業委員會林務局，"運用光學衛星影像於全島崩塌地判釋與災害分析(102-103 年)"，2014。
6. 行政院農業委員會林務局，"運用光學衛星影像於全島崩塌地判釋與災害分析(104-105 年)"，2017。
7. 李錫堤，"山崩及土石流災害分析的方法學回顧與展望"，台灣公共工程學刊，第 5 卷第 1 期，2009。
8. 张玲, 杨晓平, 魏占玉, and 黄伟亮，"三维数据的二维可视化方法综述"，地震地质，第 36 卷第 1 期，275-284 頁，2014。
9. Abella, E. A. C. and Van Westen, C. J., "Generation of a landslide risk index map for Cuba using spatial multi-criteria evaluation," Landslides, vol. 4, no. 4, pp. 311-325, 2007.
10. Alom, M. Z., Alam, M., Taha, T. M., and Iftekharruddin, K. M., "Object recognition using cellular simultaneous recurrent networks and convolutional neural network," in 2017 International Joint Conference on Neural Networks (IJCNN), 2017, pp. 2873-2880.
11. Baum, R. L. et al., "Regional landslide-hazard assessment for Seattle, Washington, USA," Landslides, vol. 2, no. 4, pp. 266-279, 2005.
12. Bishop, C. M., Pattern Recognition and Machine Learning

- (Information Science and Statistics). Springer-Verlag, 2006.
13. Canli, E., Thiebes, B., Petschko, H., and Glade, T., Comparing physically-based and statistical landslide susceptibility model outputs -a case study from Lower Austria. 2015.
 14. Chen, R. F., Lin, C. W., Chen, Y. H., He, T. C., and Fei, L. Y., "Detecting and Characterizing Active Thrust Fault and Deep-Seated Landslides in Dense Forest Areas of Southern Taiwan Using Airborne LiDAR DEM," Remote Sensing, Article vol. 7, no. 11, pp. 15443-15466, Nov 2015.
 15. Chiba, T., Kaneta, S. I., and Suzuki, Y., "Red relief image map: new visualization method for three dimensional data," The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, vol. 37, pp. 1071-1076, 2008.
 16. Choi, K. Y. and Cheung, R. W. M., "Landslide disaster prevention and mitigation through works in Hong Kong," Journal of Rock Mechanics and Geotechnical Engineering, vol. 5, no. 5, pp. 354-365, 2013.
 17. Chung, C.-J. F. and Fabbri, A. G., "Validation of Spatial Prediction Models for Landslide Hazard Mapping," Natural Hazards, vol. 30, no. 3, pp. 451-472, 2003.
 18. Costanzo, D., Rotigliano, E., Irigaray, C., Jiménez-Perálvarez, J. D., and Chacón, J., "Factors selection in landslide susceptibility modelling on large scale following the gis matrix method: application to the river Beiro basin (Spain)," Natural Hazards and Earth System Sciences, vol. 12, no. 2, pp. 327-340, 2012.
 19. Deng, Y., Bao, F., Kong, Y., Ren, Z., and Dai, Q., "Deep Direct Reinforcement Learning for Financial Signal Representation and Trading," IEEE Transactions on Neural Networks and Learning Systems, vol. 28, no. 3, pp. 653-664, 2017.
 20. Drönner, J. et al., "Fast Cloud Segmentation Using Convolutional

- Neural Networks," *Remote Sensing*, vol. 10, no. 11, 2018.
21. Favalli, M. and Fornaciai, A., "Visualization and comparison of DEM-derived parameters. Application to volcanic areas," *Geomorphology*, Article vol. 290, pp. 69-84, Aug 2017.
 22. Fourniadis, I. G., Liu, J. G., and Mason, P. J., "Landslide hazard assessment in the Three Gorges area, China, using ASTER imagery: Wushan–Badong," *Geomorphology*, vol. 84, no. 1-2, pp. 126-144, 2007.
 23. Frattini, P., Crosta, G., and Carrara, A., "Techniques for evaluating the performance of landslide susceptibility models," *Engineering Geology*, vol. 111, no. 1-4, pp. 62-72, 2010.
 24. Glade, T., "Landslide occurrence as a response to land use change: a review of evidence from New Zealand," *Catena*, vol. 51, no. 3-4, pp. 297-314, 2003.
 25. Glenn, N. F., Streutker, D. R., Chadwick, D. J., Thackray, G. D., and Dorsch, S. J., "Analysis of LiDAR-derived topographic information for characterizing and differentiating landslide morphology and activity," *Geomorphology*, vol. 73, no. 1-2, pp. 131-148, 2006.
 26. Godt, J. W., Baum, R. L., Savage, W. Z., Salciarini, D., Schulz, W. H., and Harp, E. L., "Transient deterministic shallow landslide modeling: Requirements for susceptibility and hazard assessments in a GIS framework," *Engineering Geology*, vol. 102, no. 3-4, pp. 214-226, 2008.
 27. Hanley, J. A. and McNeil, B. J., "A method of comparing the areas under receiver operating characteristic curves derived from the same cases," vol. 148, no. 3, pp. 839-843, 1983.
 28. He, K., Zhang, X., Ren, S., and Sun, J., "Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification,"

- in 2015 IEEE International Conference on Computer Vision (ICCV), 2015, pp. 1026-1034.
29. Highland, L. M. and Bobrowsky, P., The Landslide Handbook: A Guide to Understanding Landslides: U.S. Geological Survey, 2008. [Online]. Available.
 30. Hong, Y.-M. and Wan, S., "Forecasting groundwater level fluctuations for rainfall-induced landslide," Natural Hazards, vol. 57, no. 2, pp. 167-184, 2010.
 31. Hong, Y., Adler, R., and Huffman, G., "Evaluation of the potential of NASA multi-satellite precipitation analysis in global landslide hazard assessment," Geophysical Research Letters, vol. 33, no. 22, 2006.
 32. Hong, Y. and Adler, R. F., "Predicting global landslide spatiotemporal distribution: Integrating landslide susceptibility zoning techniques and real-time satellite rainfall estimates," International Journal of Sediment Research, vol. 23, no. 3, pp. 249-257, 2008.
 33. Huang, G., Liu, Z., van der Maaten, L., and Weinberger, K. Q., "Densely Connected Convolutional Networks," ArXiv e-prints, vol. 1608, Accessed on: August 1, 2016 Available: <http://adsabs.harvard.edu/abs/2016arXiv160806993H>
 34. Inomata, T. et al., "Archaeological Application of Airborne LiDAR with Object-Based Vegetation Classification and Visualization Techniques at the Lowland Maya Site of Ceibal, Guatemala," Remote Sensing, Article vol. 9, no. 6, p. 27, Jun 2017, Art. no. 563.
 35. Kampffmeyer, M., Salberg, A., and Jenssen, R., "Semantic Segmentation of Small Objects and Modeling of Uncertainty in Urban Remote Sensing Images Using Deep Convolutional Neural Networks," in 2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2016, pp. 680-688.
 36. Karatson, D., Yepes, J., Favalli, M., Rodriguez-Peces, M. J., and

- Fomacai, A., "Reconstructing eroded paleovolcanoes on Gran Canaria, Canary Islands, using advanced geomorphometry," *Geomorphology*, Article vol. 253, pp. 123-134, Jan 2016.
37. Kirschbaum, D. B., Adler, R., Hong, Y., Hill, S., and Lerner-Lam, A., "A global landslide catalog for hazard applications: method, results, and limitations," *Natural Hazards*, vol. 52, no. 3, pp. 561-575, 2009.
38. Kirschbaum, D. B., Adler, R., Hong, Y., and Lerner-Lam, A., "Evaluation of a preliminary satellite-based landslide hazard algorithm using global landslide inventories," *Natural Hazards and Earth System Sciences*, vol. 9, no. 3, pp. 673-686, 2009.
39. Koukis, G. and Ziourkas, C., "Slope instability phenomena in Greece: A statistical analysis," *Bulletin of the International Association of Engineering Geology - Bulletin de l'Association Internationale de Géologie de l'Ingénieur*, vol. 43, no. 1, pp. 47-60, 1991/04/01 1991.
40. Lee, E. M. and Jones, D. K. C., *Landslide risk assessment*. Thomas Telford, London, 2004.
41. Lee, S. and Pradhan, B., "Landslide hazard mapping at Selangor, Malaysia using frequency ratio and logistic regression models," *Landslides*, vol. 4, no. 1, pp. 33-41, 2006.
42. Lin, E.-J., Liu, C.-C., Chang, C.-H., Cheng, I.-F., and Ko, M.-H., "Using the FORMOSAT-2 high spatial and temporal resolution multispectral image for analysis and interpretation landslide disasters in Taiwan," *Journal of Photogrammetry and Remote Sensing*, vol. 17, no. 1, pp. 31-51, 2013.
43. Lin, T., Goyal, P., Girshick, R., He, K., and Dollár, P., "Focal Loss for Dense Object Detection," in *2017 IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 2999-3007.
44. Lin, Z., Kaneda, H., Mukoyama, S., Asada, N., and Chiba, T.,

- "Detection of subtle tectonic-geomorphic features in densely forested mountains by very high-resolution airborne LiDAR survey," *Geomorphology*, Article vol. 182, pp. 104-115, Jan 2013.
45. Liu, C.-C. and Chen, P.-L., "Automatic extraction of ground control regions and orthorectification of Formosat-2 imagery," *Optics Express*, vol. 17, no. 10, pp. 7970-7984, 2009.
 46. Liu, C.-C. et al., "Clouds Classification from Sentinel-2 Imagery with Deep Residual Learning and Semantic Image Segmentation," *Remote Sensing*, vol. 11, no. 2, 2019.
 47. Liu, C., "Processing of FORMOSAT-2 Daily Revisit Imagery for Site Surveillance," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44, no. 11, pp. 3206-3214, 2006.
 48. Liu, C. C., Luo, W., Chen, M. C., Lin, Y. T., and Wen, H. L., "A new region-based preparatory factor for landslide susceptibility models: the total flux," *Landslides*, vol. 13, no. 5, pp. 1049-1056, 2015.
 49. Liu, J. G. et al., "Landslide hazard assessment in the Three Gorges area of the Yangtze river using ASTER imagery: Zigui-Badong," *Geomorphology*, vol. 61, no. 1-2, pp. 171-187, 2004.
 50. Liu, P., Zhang, H., and Eom, K. B., "Active Deep Learning for Classification of Hyperspectral Images," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 2, pp. 712-724, 2017.
 51. Luo, W. and Liu, C.-C., "Innovative landslide susceptibility mapping supported by geomorphon and geographical detector methods," *Landslides*, Article vol. 15, no. 3, pp. 465-474, 3/1 2018.
 52. Nagpal, S., Singh, M., Singh, R., and Vatsa, M., "Regularized Deep Learning for Face Recognition With Weight Variations," *IEEE Access*, vol. 3, pp. 3010-3018, 2015.
 53. Oh, H.-J. and Lee, S., "Cross-application used to validate landslide

- susceptibility maps using a probabilistic model from Korea," Environmental Earth Sciences, vol. 64, no. 2, pp. 395-409, 2010.
54. Pardeshi, S. D., Autade, S. E., and Pardeshi, S. S., "Landslide hazard assessment: recent trends and techniques," Springerplus, vol. 2, p. 523, 2013.
55. Parise, M. and Gunn, J., Natural and Anthropogenic Hazards in Karst Areas: Recognition, Analysis and Mitigation. 2007.
56. Ravi, D. et al., "Deep Learning for Health Informatics," IEEE Journal of Biomedical and Health Informatics, vol. 21, no. 1, pp. 4-21, 2017.
57. Reichenbach, P., Busca, C., Mondini, A. C., and Rossi, M., "The influence of land use change on landslide susceptibility zonation: the Briga catchment test site (Messina, Italy)," Environ Manage, vol. 54, no. 6, pp. 1372-84, Dec 2014.
58. Ronneberger, O., Fischer, P., and Brox, T., "U-Net: Convolutional Networks for Biomedical Image Segmentation," ArXiv e-prints, vol. 1505, Accessed on: May 1, 2015 Available: <http://adsabs.harvard.edu/abs/2015arXiv150504597R>
59. Süzen, M. L. and Kaya, B. Ş., "Evaluation of environmental parameters in logistic regression models for landslide susceptibility mapping," International Journal of Digital Earth, vol. 5, no. 4, pp. 338-355, 2012.
60. Shahabi, H. and Hashim, M., "Landslide susceptibility mapping using GIS-based statistical models and Remote sensing data in tropical environment," Scientific Reports, Article vol. 5, p. 9899, 04/22/online 2015.
61. Shahabi, H. and Hashim, M., "Landslide susceptibility mapping using GIS-based statistical models and Remote sensing data in tropical environment," Sci Rep, vol. 5, p. 9899, Apr 22 2015.

62. Shou, K., Chen, Y., and Liu, H., "Hazard analysis of Li-shan landslide in Taiwan," *Geomorphology*, vol. 103, no. 1, pp. 143-153, 2009.
63. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. J. T. j. o. m. l. r., "Dropout: a simple way to prevent neural networks from overfitting," *JOURNAL OF MACHINE LEARNING RESEARCH*, vol. 15, no. 1, pp. 1929-1958, 2014.
64. Stillwell, J., *Mathematics and Its History*. Springer New York, 2010.
65. Szegedy, C. et al., "Going deeper with convolutions," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 1-9.
66. van Westen, C. J., Castellanos, E., and Kuriakose, S. L., "Spatial data for landslide susceptibility, hazard, and vulnerability assessment: An overview," *Engineering Geology*, vol. 102, no. 3-4, pp. 112-131, 2008.
67. Wu, Y. et al., "Landslide susceptibility assessment using frequency ratio, statistical index and certainty factor models for the Gangu County, China," *Arabian Journal of Geosciences*, vol. 9, no. 2, 2016.
68. Yokoyama, R., Shirasawa, M., and Pike, R. J., "Visualizing topography by openness: a new application of image processing to digital elevation models," *Photogrammetric engineering and remote sensing*, vol. 68, no. 3, pp. 257-266, 2002.
69. Zhan, Y., Wang, J., Shi, J., Cheng, G., Yao, L., and Sun, W., "Distinguishing Cloud and Snow in Satellite Images via Deep Convolutional Network," *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 10, pp. 1785-1789, 2017.

附錄

附錄一、期初審查會議記錄暨回覆辦理情形

壹、時間：108 年 5 月 30 日（星期四）下午 1 時

貳、地點：本局第五會議室

參、主持人：陳副總工程司振宇

記錄：陳國威

肆、出（列）席單位人員：詳簽到簿。

伍、受委託單位簡報：略。

陸、審查意見及回覆辦理情形

項次	審查意見	回覆辦理情形
報告內容審查意見：		
一	建議可以崩塌前的紅色地圖與事後有崩塌的地點進行比較及訓練（如紅葉村），試著以AI方式找出未來可能崩塌的地點，期望未來能以AI協助由紅色地圖找出相關崩塌區位。	感謝委員的建議，目前崩塌潛勢指標模式的建立，訓練資料使用歷年崩塌目錄，可利用大數據之優勢，訓練出較符合實際發生狀況的崩塌潛勢指標模式，局部區域的事件型崩塌目錄資料，需要再持續累積資料，等累積到一定資料量後，再拿來作機器學習的訓練，相信一定能夠更準確。

項次	審查意見	回覆辦理情形
二	本研究應用紅色地圖通過機械學習方法判釋崩塌潛感區，試說明判釋原理為何？目前應用紅色地圖判釋崩塌潛感係利用其微地形特徵為依據，惟目前研究方法係利用大尺度因子作為交集提供判斷，這跟紅色地圖判讀完全不同。	感謝委員提問，目前深度學習方法中，卷積神經網路已大量運用於影像特徵的辨識，本研究希望能透過紅色地圖在微地形特徵的突出性質，可以提供深度學習可辨識的可能崩塌地形的影像特徵，可以讓深度學習的模式預測更加準確。
三	機械學習採用坡度及坡向係崩塌前或後的地形資料？	感謝委員提問，目前的崩塌目錄是 13 年的累積崩塌資料。因子的部份都是來自同一個 DEM，所以拿不是崩塌前崩塌後的資料做計算，這個 DEM 可能是發生某些崩塌之前的，但同時也是發生某些崩塌之後的。
四	以崩塌目錄為訓練目標，但同樣之坡度、坡向、岩質而未崩塌之對象更多，如何解釋？	感謝委員提問，崩塌潛勢指標係利用大量的數據，統計與運算出該區域發生崩塌的可能性，簡單的解釋可以是在同樣的坡度、坡向、累積流量、岩性的區域中，發生崩塌與未發生崩塌的比例。所以訓練資料會包含研究區域中，所有曾發

項次	審查意見	回覆辦理情形
		生崩塌與未發生崩塌的區域。
五	所採訓練項目是否具連續性，將影響判釋之誤導。後設機率之母數何在？	感謝委員提問，目前訓練的資料，以 5 公尺解析度的像素點為資料單元，所以是具有連續性的。後設機率的母數全研究區域的特徵圖。在過去的研究裡面，的確有分為崩塌區和非崩塌區，決定的門檻值就是必須是一個 trade-off，要在崩塌區能夠達到一個極值，在非崩塌區也能夠達到一個極值，所以在判的時候，2 種區域是分開來的，母數樣本空間有分開來，但是最終決定的值是在 2 個空間是符合的，在卷積類神經網路裡面，我們希望它能辨識出崩塌因子間的空間特徵，所以必須整張影像丟進去，沒有分開崩塌與非崩塌。

項次	審查意見	回覆辦理情形
六	以坡度、坡向、岩性及總流通量為分析因子，是否也可運用於地震引致坡地災害潛勢？宜加說明。	感謝委員的建議，地震與降雨為誘發崩塌的因子，坡度、坡向岩性及總流通量為潛勢因子，課題限縮在潛勢因子，沒有考慮地震和降雨，先把問題單純化，一步步將問題釐清，相關敘述已補充已報告書中。
七	表 2-2 (pp. 2-11) 岩性，宜採地質類別？	岩性的部份，是中央地調所給的地質圖，在大地科學可能會更講究，有更多的考量，但是目前手上有的最詳細的資料，就是地質圖，能夠區分不同的岩石組成，所以就用這個參數，若有更好的參數，可以拿到資料，應該可以放上去做分析。
八	使用 CloudNet 是自主研發或共享或商業軟體架構？宜加說明。	感謝委員的建議，CloudNet 是本研究團隊於去年研究雲判釋所建構之深度學習模式，相關說明已補充於方法中，並引用已發表之文獻，請參閱。

項次	審查意見	回覆辦理情形
九	請說明崩塌潛感模式的訓練次數及準確率。	感謝委員的建議，相關內容已補充已方法與結果中。
十	請說明成功率曲線、CPOLO-LSI在崩塌判定上之尺寸大小、範圍的判定或判釋。	感謝委員的建議，成功率曲線與 CPOLO 已在方法中說明，由於本研究在建立崩塌潛勢指標的預估模式，並透過一些指標，判斷建立的模式的好壞，並非進行實際的判釋。 崩塌判釋是另一個工作，建一個崩塌目錄，在目錄上面根據前期後期去比對，考慮山坡地是否有可能發生崩塌的潛勢，所以很平坦的地方應該不是，或人為開發的不是，所以它的判釋的單元的確是一個像素(pixel)，若有一個像素，它植被發生變化，之前沒有後來有的話，它是以一個 pixel 為單位來計算。

附錄二、期中報告書審查意見暨回覆辦理情形

項次	審查意見	回覆辦理情形
報告書內容審查意見：		
一	請評估岩性是否可將岩石力學之強度概念融入？	感謝委員的建議，目前岩性的資料取自中央地調所公布的五萬分之一地質圖，屬於岩石性質的分類資料，所以並無岩石力學之強度概念。
二	請加強說明，ROC曲線下花蓮比宜蘭差。	感謝委員的建議，已在第5章第4節 P5-18 加強說明。
三	P2-6中提到，將以坡度、坡向、岩性及總流通量作為建議標準LSM的主要潛勢因素，惟後續「總流通量」部份係以「累積通量」值代替，這部份是否誤植，再請確認。另外，建議在內文中針對累積流通量進行說明。	感謝委員指出文中的問題，文中「總流通量」與「累積通量」係指同一因子，已統一中文名稱。

項次	審查意見	回覆辦理情形
四	P2-19及2-20之內文中皆有提到「下圖」，惟文內尚無看到任何相關圖示，請檢查是否誤植。	感謝委員指出文中的問題，圖片已補上（圖 3-17、圖 3-18）。
五	P2-20「梯度消失」出現兩種定義，其中一種應為「梯度爆炸」。	感謝委員指出文中問題，已將第 2 個「梯度消失」的名詞更正為「梯度爆炸」，見 P3-22。
六	關鍵英語用詞之中文詞義如 P-19 Gradient Descent 等，部分文中雖已提及，但仍建議在大標處加入中文詞義。	感謝委員的建議，除了大標題加入中文詞義外，文中將以中文為主要用詞，維持文中風格的一致性。
七	此研究中，P4-9最後結論提到係利用紅色地圖結合測試出最佳之潛勢因子組合進行訓練模式，其中最佳潛勢因子組合係為「坡度 (S)+編碼後坡向 (AE)+累積通量 (TF)+編碼後岩性 (GME)+ 數值高程 (DEM)」，這些因子當中，與紅色地圖組成之元素有些許	感謝委員的提問，因為深度學習的架構中有一些排除和降低特徵重要性的架構和演算法，包括 regularization (P3-26) 和 knockout (P3-26)，所以研究中才將所有因子給考慮進去。

項次	審查意見	回覆辦理情形
	重複，包括坡度 (S) 及高程 (DEM)，是否會在類神經計算分析時產生重複計算之虞慮，請加以說明。	

附錄三、期末報告審查意見暨回覆辦理情形

壹、時間：108 年 12 月 3 日（星期二）下午 9 時 15 分起

貳、地點：公務人力發展學院(南投院區) 文教大樓 7 樓 704 教室

參、主持人：柯總工程司燦堂(場次 D1)

肆、出（列）席單位人員：略

記錄：陳國威

伍、計畫主持人簡報:略

陸、審查意見及回覆辦理情形

項次	審查意見	回覆辦理情形
報告書內容會前審查意見：		
一	p5-6的公式寫Wl，但下文卻寫Wn，是否誤植？	感謝技研小組指出文中的問題，Wn 確實為誤植，已在文中修正 (P5-6)，。
二	文中指出岩性、坡向、坡度、累積通量為重要因子，且紅色地圖之重要性亦小於DEM，考量實務上之效率與所得之準確性，未來是否建議不必要多納入紅色地圖做為該方法潛勢判釋模型之因子？	感謝技研小組提問，研究結果比較紅色地圖和 DEM，是在包含其他 4 種因子的模式，紅色地圖的組成包含坡度，所以它對於預估崩塌潛勢指標的作用某部份可能被坡度所取代，但是從第 5 章第 4 節的第一個結果顯示，6 個因子的模式比 5 個因子為佳，表示紅色地圖的另一個組成開闊度可能對崩塌潛勢指標的預估有貢獻，建議未來可以嘗試把紅

項次	審查意見	回覆辦理情形
		色因子另一個組成因子納入潛勢因子研究看看，而不是直接以紅色地圖的 R、G、B 作分析。
三	是否有評估未來以人工智慧結合紅色地圖方式萃取現生崩塌之判定？	感謝技研小組提問，人工智慧的演算法適合作有明確答案的物件偵測與辨識，現生崩塌的判定也屬於該範籌，確實是個有潛力的研究。紅色地圖的資料來自數值高程，需先確認數值高程資料拍攝時該崩塌需存在於畫面上，建議未來先建立這樣的資料配對，累積足夠的資料，再進行研究。
期末聯合審查意見：		
一	建議於內文中說明模式選擇之比對(優缺點)。	感謝委員的建議，目前模式的優劣的評估標準為接收者操作特徵曲線下面積，面積越大表示建立的模式預測的正確性越高，詳細評估方法已描述於第四章第三節。

項次	審查意見	回覆辦理情形
二	Cloudnet 日後是否開放使用？請說明。	感謝委員的提問，CloudNet 是本研究團隊於去年研究雲判釋所建構之深度學習模式，著作權屬於資工所的一位畢業生，目前並無版權宣告，未來如有開放使用的需求，會進一步取得該作者的同意。
三	紅色地圖產製所需經費較高，是否有更快速且對水保局更有效可用的簡易模式建議？請說明。	感謝委員的提問，在第五章第四節關於潛勢因子選擇的組合中，前 6 種組合的 AUC ROC 值皆在 0.84 以上（圖 5-8），表示這幾種模式在辨識崩塌與非崩塌區域的能力都不錯，其中排名第 4 的 4 個因子組合，過去使用幾何模型預測 LSI 的成果就不錯（Liu, et al. 2015），在深度學習的模式中，成功率曲線下面積的表現僅略低於 6 個因子的模式，所以若考慮紅色地圖的產製成本過高，建議可以使用坡度、坡向、岩性和累積通量等 4 個因子的模式。

項次	審查意見	回覆辦理情形
四	紅色地圖係由坡度及開闊度所組成，而坡度在原 LSI 中已考慮，建議改用開闊度圖當作判釋依據之一。	感謝委員的建議，原本研究的最初，也有考慮把紅色地圖的組成因子納進來作為潛勢因子，不過由於此研究主要探討紅色地圖，並且利用卷積神經網路架構，辨識易崩塌地區在紅色地圖上的圖形特徵，所以此研究還是以紅色地圖的紅綠藍三個波段的數值建立模式，而且紅色地圖是一種經過專家研究後，特徵轉換過的因子，應該認為是比原始因子更有鑑別度的因子。不過從研究的成果可以發現，若把開闊度從紅色地圖獨立出來，應該可進一步簡化模式，因為另一個坡度因子已經考慮為另一個潛勢因子，此研究已經把崩塌潛勢的模式架構建立起來，未來可以進一步測試坡向因子的效果。

項次	審查意見	回覆辦理情形
五	後續研究建議加入更多地理資訊條件，以精緻化 AI 判釋。	感謝委員的建議，未來會考慮將崩勢潛勢指標結合地理資訊，提供更完善的資訊，協助崩塌預警的判釋。
六	因崩塌因素甚複雜，此研究建立之模式宜經更多事件及時間檢核、修正，其能更為完善及有效應用。	感謝委員的建議，未來擬以本研究之模式預估之崩塌潛勢指標，針對高潛勢之崩塌區域，驗證此模式的正確性，並且探討可能發生錯誤估計的原因，進一步改善模式，以提升模式預估的精確度。
七	此研究係以106年前之資料訓練，建議以107.108 年資料予以驗證，提出判釋之準確度。	感謝委員的建議，目前 107、108 年新生崩塌資料正在逐步判釋與整理，未來將可採納委員的建議，進一步驗證崩塌潛勢指標的準確度。
八	有關 LSI 指標改善率達 480%，宜再進一步說明。	感謝委員的建議，此 LSI 指標改善率係與 Luo and Liu (2018) 發表於期刊 Landslides 的研究作比較，文章中先前說明較不清楚，已在第六章補充說明。過去研究的崩塌潛勢指標模式，在預估之

項次	審查意見	回覆辦理情形
		崩塌潛勢指標排名前 1% 的正確率有明顯的限制，只有 6.8% 曾發生崩塌，此研究提出的卷積崩塌潛勢指標模式，則可達 39.4%，是一個很大的進展。
九	有關文中以紅色地圖為因子不易了解，建議轉換為量化因子。	感謝委員的建議，目前深度學習的影像分析，是取影像的 RGB 波段數值 (1~255) 進行分析，所以亦為量化之因子，已補充說明於第四章第一節。

附錄四、2019 臺灣地球科學聯合學術研討會摘要

以深度學習卷積神經網路建置宜蘭地區崩塌潛感指標圖 Mapping the landslide susceptibility index in I-Lan area with deep learning and convolutional neural network

賴建志¹ 劉正千^{1,2} 吳振佑³ 陳振宇³ 陳培殷⁴

¹ 國立成功大學全球觀測與資料分析中心

² 國立成功大學地球科學系暨研究所

³ 行政院農業委員會水土保持局

⁴ 國立成功大學資訊工程學系暨研究所

摘 要

根據長期且詳盡的崩塌目錄，建立可靠的崩塌潛勢指標 (Landslide Susceptibility Index, LSI)圖，是預防和減輕崩塌危害最重要的資訊之一。過去一般的作法是假設LSI由若干潛勢因子所決定，根據歷史崩塌紀錄，採取不同的統計分析方法以建立函數模型，並經由迭代觀測數據進行擬合，找出各潛勢因子的權重，進而計算LSI，建置LSI圖。此種作法因為必須先設定了LSI與潛勢因子間的關係，儘管可以引進更多潛勢因子、考慮更複雜的交互關係、採用更詳盡的崩塌目錄，其能夠達成的精度總是受到限制。尤其是當使用的變量越多，或者輸入因子與輸出現象關係原本就非常複雜，實在無法、也不應該設定LSI與潛勢因子間為單一函數關係，強行擬合分析。

深度學習 (Deep Learning) 使用多層神經網路模擬出複雜的關係，可視為是一種自動化的特徵轉換，由原始資料轉換至特徵空間，可以對資料進行擬合。卷積神經網路 (Convolutional Neural Network, CNN) 使用濾波 (filter) 進行影像的特徵萃取，減少模型的參數數量，比起深度神經網路 (Deep Neural Network, DNN) 能更有效率地進行模式訓練。本團隊已成功改良 atrous spatial pyramid pooling (ASPP) 模式，結合殘差學習 (residual learning) 並移除降維取樣 (down sampling) 程序，建立CloudNet架構，實際應用於衛星影像對於雲霧的辨識處理。本研究採用深度學習卷積神經網路為架構，以宜蘭太平山地區之坡度圖、岩性圖、坡向圖、累積通量圖為特徵影像作為訓練之輸入資料，並且以林務局所建置2005至2016年之崩塌目錄為訓練目標。不同於一般深度學習進行分類之應用，本研究由各種崩塌相關的潛勢因子估計可能發生崩塌的機率，將透過梯度下降法和反向傳播法進行擬合，找出各神經元的最佳權重，最後的輸出層Softmax函式，將輸出後測機率 (posterior probability)，以此機率建立崩塌潛感指標圖。

透過深度學習所建立準確的崩塌潛感指標地圖，可評估高致災潛勢之災害熱點，進行崩塌災害的預警，以預防取代救災行動，達到減少崩塌災損的情況。未來再結合考量了開闢度與坡度的紅色地圖 (Red Relief Image Map, RRIM)，其加強了地形在影像視覺上的特徵，預期可更進一步提升崩塌潛感指標的準確性。

附錄五、2019 地球觀測及社會衝擊國際研討會摘要

Deep learning with red relief map for mapping the landslide susceptibility index in I-Lan area

Chien-Chih Lai¹, Cheng-Chien Liu^{1,2}, Chen-Yu Wu³, Chen-Yu Chen³, Pei-Yin Chen⁴

¹Global Earth Observation and Data Analysis Center, National Cheng Kung University, Tainan City 70101, Taiwan; ccliu88@mail.ncku.edu.tw (C.Liu); z10604034@email.ncku.edu.tw (C.Lai);

²Department of Earth Sciences, National Cheng Kung University, Tainan City 70101, Taiwan

³Soil and Water Conservation Bureau, Nantou County 54044, Taiwan; owen951753@mail.swcb.gov.tw (C.Wu); cychen@mail.swcb.gov.tw (C.Chen)

⁴Department of Computer Science and Information Engineering, National Cheng Kung University, Tainan City 70101, Taiwan; pychen@mail.ncku.edu.tw (P.Chen)

ABSTRACT

Establishing a reliable landslide susceptibility index (LSI) map based on a long-term and detailed landslides inventories is one of the most important missions to prevent and mitigate the risk of landslides. In the past, the general method was to assume that LSI is determined by several preparatory factors which are analyzed in different statistical analysis methods. A functional model is constructed by fitting the observation data to find the weight of each potential factor iteratively. Such an approach does not take spatial information into consideration in the model or needs to adapt spatially relevant potential factors with expert knowledge, such as hydrological flux. In recent years, due to the advancement of big data technology and parallel computing hardware, deep learning image recognition has also expanded rapidly. The Convolutional Neural Network (CNN) uses filters to extract features from images. After the fully convolutional network (FCN) was proposed, the image classification was evolved from the full image classification to a single pixel level, which is called the semantic image segmentation. The characteristics and spatial pattern of the preparatory factor maps might be extracted by FCN to establish a reliable landslide susceptibility index map.

Visualized characteristics of the preparatory factor maps are not generally difficult to identify by human eyes. To overcome this problem, the red relief image map (RRIM) proposed by Chiba et al., which presents the slope and openness of topography by redness and brightness respectively in the image. Without shading by simulating incident light direction, the RRIM can express the fine topographic structure and even the topographic characteristics of landslides. This study proposes to use fully convolutional neural network for semantic image segmentation. In addition to the commonly obtainable and applicable preparatory factor maps, the RGB bands of the RRIM would be used to improve the training model of the FCN. The general preparatory factors consist of the slope, aspect, lithology, and total flux which were calculated and collected in 5-m resolution from the DEM of the Taipingshan area in I-Lan. While the preparatory factors and the RGB bands of the RRIM are the input of the training model, the landslide inventory data established by a semi-automatic expert system from 2005 to 2016 are the label data as the training target. Except for the classification task of deep learning, our model needs to estimate the landslide susceptibility probability which may be defined as the posterior probability of landslides while the preparatory factors exist. The final output layer of the model is the softmax function which would represent the posterior probability of landslides. The landslide susceptibility index model evaluated in this study would establish an accurate map of the landslide susceptibility index, which may assess the hot spots of high-risk potential disasters, and provide early warning of landslide disasters to prevent the loss and damage the landslides.

附錄六、2019 地球觀測及社會衝擊國際研討會海報發表


Deep learning with red relief image map for mapping the landslide susceptibility index in I-Lan area

Chien-Chih Lai, Cheng-Chien Liu, Chen-Yu Wu, Chen-Yu Chen, Pei-Yin Chen

1. Landslide susceptibility index (LSI) is essential to the areas susceptible to landsliding.

In order to mitigate and prevent the losses due to landslides, various measures such as planning evacuation routes and issuing early warnings have been developed. These measures depend on the landslide susceptibility mapping to identify the areas which are susceptible to landsliding.

2. Preparatory factors should be obtainable and applicable anywhere.



3. Multi-variate models did not account for the different contribution of various preparatory factors.

The geometric mean model: $LSI(f) = \frac{1}{m} \sum_{i=1}^m W_{pfs}(i_k)$, where W_{pfs} is the weight of preparatory factor at interval i which is defined as the frequency ratio of the landslide ratio to the area ratio at interval i .

Lin, C.-C*, Luo, W., Chen, M.-C., Lin, Y.-T., and Wen, H.-I. (2016) A new region-based preparatory factor for landslide susceptibility models: the total flux. *Landslides*, 13:1049 (doi:10.1007/s10346-015-0620-3)

4. Cloudnet has been validated to be an useful convolutional neural network (CNN) architecture for image segmentation in cloud classification

Residual training can keep spatial information through the deep network process.
Atrous Spatial Pyramid Pooling (ASPP) can handle the multi-scale image features.

Lin, C.-C*, Zhang, Y.-C., Chen, P.-Y., Lai, C.-C., Chen, Y.-H., Cheng, J.-H., Ko, M.-H. (2019) Clouds classification from Sentinel-2 imagery with deep residual learning and semantic image segmentation. *Remote Sensing*, 11(2), 119.

5. In our preliminary studies, the LSI model based on Cloudnet architecture can improve the performance of the prediction at the top 1% highly susceptible area.

The percentage of improvement is 193% at the top 1% rank
However, the performance inside the top 20% ranks is still lower than the multi-variate model (Liu et al. 2016) and the newly developed spatial variance method (Luo and Liu 2018).

Comparison of the percentage of the landslides at top 1%, 10%, and 20% LSI rank on previous studies and Cloudnet LSI model.

Rank (%)	Liu et al. 2016	Luo and Liu 2018	Cloudnet model
1	6.0%	6.8%	20.0%
10	42.0%	42.1%	36.5%
20	62.0%	63.4%	55.7%

Luo, W* and Liu, C.-C. (2017) Innovative landslide susceptibility mapping supported by geomorphon and geographical detector methods. *Landslides*.
<https://doi.org/10.1007/s10346-017-0893-9>.

6. Red relief image map (RRIM) can express the fine topographic characteristics of landslides.

Represent the slope and openness of topography by redness and brightness.
Provide 3D perspective visualization without any aid.
Should be equipped to have precise features for CNN training.

RRIM



7. To get more landslide area data, the study site, I-Lan area, in which many landslides were occurred in the past years was picked.

Located in the northeast part of Taiwan.
Altitude from 10-100 m a.s.l to ~2000 m a.s.l.
Vulnerable to typhoons and extreme precipitation.

8. Feature engineering

The slope (0~90°), aspect (0~360°) and total flux (floating number) did not need to transform as well as the RGB bands (0~255) of the RRIM.

The lithology feature is nominal data provided by the Central Geological Survey of Taiwan, which will be encoded with one-hot encoding scheme.

9. The cumulative percentages of landslide occurrence (CPOLO) are commonly used to access the performance of the LSI.

The steeper the CPOLO curve, the better the capability of LSM to predict landslides.
The performance is improved after the feature engineering without RRIM.

10. Adding the RRIM to LSI model did not raise the performance of the CPOLO curve.

The curvature of the CPOLO curve drops after incorporating the RRIM data.

11. Summary

Currently, we have not found the good performance while integrating the RRIM into the Cloudnet LSI model.
More effect may be needed to transform the preparatory features to be appropriate for reflecting the correlation between their values and landslide susceptibility.
Other deep learning models may be examined in the future.

